



การพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าเพื่อระบบเตารีดอัจฉริยะที่ควบคุม
อุณหภูมิอัตโนมัติ



วชิระ ลิ่มศรีประพันธ์

วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนเรศวร
เพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรปรัชญาดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์
ปีการศึกษา 2565
ลิขสิทธิ์เป็นของมหาวิทยาลัยนเรศวร

การพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าเพื่อระบบเตารีดอัจฉริยะที่ควบคุม
อุณหภูมิอัตโนมัติ



วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนครสวรรค์
เพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรปรัชญาดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์
ปีการศึกษา 2565
ลิขสิทธิ์เป็นของมหาวิทยาลัยนครสวรรค์

วิทยานิพนธ์ เรื่อง "การพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าเพื่อระบบเตารีดอัจฉริยะที่
ควบคุมอุณหภูมิอัตโนมัติ"
ของ วชิระ ลิ้มศรีประพันธ์
ได้รับการพิจารณาให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการสอบวิทยานิพนธ์
(รองศาสตราจารย์ ดร.วิระสิทธิ์ อิ่มถวิล)

..... ประธานที่ปรึกษาวิทยานิพนธ์
(รองศาสตราจารย์ ดร.สุชาติ แยมเม่น)

..... กรรมการที่ปรึกษาวิทยานิพนธ์
(ศาสตราจารย์ ดร.ไพศาล มุณีสว่าง)

..... กรรมการผู้ทรงคุณวุฒิภายใน
(ผู้ช่วยศาสตราจารย์ ดร.ปิยนัย ภาชนะพรรณ)

..... กรรมการผู้ทรงคุณวุฒิภายใน
(ผู้ช่วยศาสตราจารย์ ดร.พนมขวัญ รียะมงคล)

อนุมัติ

.....
(รองศาสตราจารย์ ดร.กรรองกาญจน์ ชูทิพย์)
คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	การพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าเพื่อระบบเตารีดอัจฉริยะที่ควบคุมอุณหภูมิอัตโนมัติ
ผู้วิจัย	วชิระ ถิ่นศรีประพันธ์
ประธานที่ปรึกษา	รองศาสตราจารย์ ดร.สุชาติ แยมเม่น
กรรมการที่ปรึกษา	ศาสตราจารย์ ดร.ไพศาล มุณีสว่าง
ประเภทสารนิพนธ์	วิทยานิพนธ์ ปร.ด. วิศวกรรมคอมพิวเตอร์, มหาวิทยาลัยนเรศวร, 2565
คำสำคัญ	อนุกรมฟูเรียร์ของลำดับคาบ, ซัพพอร์ตเวกเตอร์แมชชีน, จำแนกสิ่งทอตามชนิดของเส้นใย, สเปกโทรสโกปีย่านใกล้อินฟราเรด

บทคัดย่อ

ปัจจุบันการจำแนกสิ่งทอตามชนิดเส้นใยผ้ากำลังเป็นประเด็นที่ได้รับความสนใจ โดยเฉพาะในด้านขยะสิ่งทอที่ส่งผลกระทบต่อในหลายมิติ ซึ่งปัญหาสำคัญ คือ ความต้องการเทคโนโลยีการจำแนกที่สามารถใช้งานร่วมกับระบบอัตโนมัติในกระบวนการคัดแยกก่อนการรีไซเคิล โดยไม่ใช้เครื่องสเปกโทรมิเตอร์ระดับห้องปฏิบัติการและสามารถทำงานบนสมองกล้องฝังตัวที่มีทรัพยากรประมวลผลจำกัด รวมถึงต่อยอดพัฒนาเป็นเครื่องใช้ไฟฟ้าอัจฉริยะที่ประหยัดพลังงานไฟฟ้าจากการกำหนดอุณหภูมิรีดให้เหมาะสมตามชนิดของเส้นใยได้ ดังนั้นผู้วิจัยจึงนำเสนออัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใยออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าเส้นใยผสม โดยใช้ข้อมูลสเปกตรัมย่านใกล้อินฟราเรดจากเซนเซอร์สเปกตรัม NeoSpectra-Micro ของผ้าตัวอย่างที่ผ่านการตรวจสอบส่วนประกอบเส้นใยตามมาตรฐาน มอก.121 เล่ม 26-2552 จำนวน 96 ผืน ผ่าน 3 ขั้นตอนหลัก คือ การนอร์มอลไลซ์สัญญาณ การสกัดเวกเตอร์คุณลักษณะใหม่ในโดเมนความถี่ของสัญญาณตัวแทนกลุ่ม และการสร้างอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนแบบ 3 คลาสสำหรับจำแนกสิ่งทอ ผลการทดสอบประสิทธิภาพอัลกอริทึมที่นำเสนอจากชุดข้อมูลสอนและทดสอบใน 3 สัดส่วน คือ กรณี 60:40 กรณี 70:30 และกรณี 80:20 พบว่า ทุกกรณีมีค่าความแม่นยำ (Precision) และค่าความระลึก (Recall) ของทุกคลาสกลุ่มเส้นใยอยู่ที่ 1.000 ± 0.000 ทำให้ค่าความถูกต้องรวมทั้งระบบ (Overall Accuracy) อยู่ที่ 1.000 ± 0.000 แสดงให้เห็นว่าวิธีการสกัดคุณลักษณะใหม่นอกจากช่วยลดจำนวนข้อมูลแล้วยังส่งผลให้อัลกอริทึมที่นำเสนอมีความแม่นยำและไม่ขึ้นอยู่กับจำนวนของข้อมูลของชุดสอนที่เปลี่ยนแปลงไป และนำผลลัพธ์ของการจำแนกไปเป็นเงื่อนไขในการกำหนดอุณหภูมิรีดที่เหมาะสม



Title	DEVELOPMENT OF A TEXTILE FIBER CLASSIFICATION ALGORITHM FOR AN AUTOMATIC TEMPERATURE CONTROLLED SMART IRON SYSTEM
Author	Wachira Limsripraphan
Advisor	Associate Professor Suchart Yammen, Ph.D.
Co-Advisor	Professor Paisarn Muneesawang, Ph.D.
Academic Paper	Ph.D. Dissertation in Computer Engineering, Naresuan University, 2022
Keywords	Discrete fourier transform, Support vector machine, Textile fiber classification, Near-infrared (NIR) spectroscopy

ABSTRACT

Currently, the classification of textiles based on fiber types has become a topic of great interest, particularly in the context of textile waste, which has multidimensional impacts. The main challenge is the need for classification technology that can be integrated with automated systems in the pre-cycling sorting process, without the use of high-spec laboratory spectrometers and the ability to operate on embedded systems with limited processing resources. Furthermore, there is a need to develop intelligent electrical appliances that conserve electricity by setting appropriate ironing temperatures according to the fiber type. Therefore, the researchers propose an algorithm for classifying textiles into three groups based on fiber types: natural fiber group, synthetic fiber group, and blended fiber group. The algorithm utilizes spectral data in the near-infrared range obtained from the NeoSpectra-Micro spectrometer sensor of the textile samples, which have undergone component verification according to the TIS.121-2552 standard. The classification process consists of three main steps: spectrum normalization, extraction of new feature vectors in the frequency domain of representative group signals, and created of a Three Class support vector machine classifier for textile classification. The performance of the proposed algorithm was evaluated through testing using training and testing datasets in three ratios: 60:40, 70:30, and 80:20. The results showed that

for all cases, the precision and recall values for all fiber groups were 1.000 ± 0.000 , resulting in an overall accuracy of 1.000 ± 0.000 . This indicates that the feature extraction method not only reduces the amount of data but also ensures the accuracy of the presented algorithm, regardless of changes in the amount of training data. Furthermore, the classification results can be used as a condition for determining appropriate ironing temperatures.



ประกาศคุณูปการ

ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงในความกรุณาของประธานที่ปรึกษาวิทยานิพนธ์ รองศาสตราจารย์ ดร.สุชาติ แย้มเม่น ที่ได้สละเวลาอันมีค่าในการอบรมสั่งสอน แนะนำองค์ความรู้ และให้คำปรึกษาด้านเทคนิคที่เกี่ยวข้องกับงานวิจัย ตลอดจนข้อเสนอแนะต่าง ๆ สำหรับการทำให้วิทยานิพนธ์เล่มนี้ จนเสร็จสมบูรณ์เป็นอย่างดี

ขอกราบขอบพระคุณท่านคณาจารย์กรรมการสอบวิทยานิพนธ์ทุกท่าน ประกอบด้วยประธานกรรมการสอบวิทยานิพนธ์และกรรมการผู้ทรงคุณวุฒิภายนอก รองศาสตราจารย์ ดร.วิระสิทธิ์ อิมถวิล ประธานที่ปรึกษาวิทยานิพนธ์รองศาสตราจารย์ ดร.สุชาติ แย้มเม่น ผู้ทรงคุณวุฒิภายใน รองศาสตราจารย์ ดร.ไพศาล มณีสว่าง ผู้ช่วยศาสตราจารย์ ดร.พนมขวัญ วิริยะ และ ผู้ช่วยศาสตราจารย์ ดร.ปิยดนัย ภาชนะพรรณน ที่ได้กรุณาให้คำแนะนำ ข้อเสนอแนะ ปรับปรุงพัฒนางานวิจัยด้วยความเอาใจใส่จนทำให้วิทยานิพนธ์เล่มนี้สำเร็จลุล่วงอย่างสมบูรณ์

ขอขอบพระคุณโครงการพัฒนานักวิจัยและงานวิจัยเพื่ออุตสาหกรรม (พวอ.) ภายใต้การดำเนินการของ สกว และห้างหุ้นส่วนจำกัด ที เจ ซัพพลาย ที่ได้มอบทุนสนับสนุนการวิจัยจนประสบผลสำเร็จ

ขอขอบพระคุณผู้ที่เกี่ยวข้องทุกท่านในภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร ที่มีส่วนร่วมในการทำให้วิทยานิพนธ์เล่มนี้จนประสบผลสำเร็จ

คุณค่าและคุณประโยชน์อันพึงจะมีจากวิทยานิพนธ์เล่มนี้ ผู้วิจัยขอมอบแด่ผู้มีพระคุณทุกท่าน และหวังเป็นอย่างยิ่งว่าวิทยานิพนธ์เล่มนี้จะเป็นประโยชน์ต่อผู้ที่สนใจนำไปใช้ได้เป็นอย่างดี หากมีข้อบกพร่องประการใดที่อาจจะเกิดขึ้นในวิทยานิพนธ์นั้น ผู้วิจัยขอน้อมรับและยินดีรับฟังคำแนะนำอันจะเป็นประโยชน์ในการพัฒนาต่อไปในอนาคต

วชิระ ลีมีศรีประพันธ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	จ
ประกาศขอบคุณการ.....	ช
สารบัญ.....	ช
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาของปัญหา.....	1
1.2 จุดมุ่งหมายของการวิจัย.....	7
1.3 ขอบเขตของการวิจัย.....	8
1.4 นิยามศัพท์เฉพาะ.....	8
1.5 สมมติฐานของการวิจัย.....	10
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	11
2.1 ข้อมูลพื้นฐานเกี่ยวกับสิ่งทอและเส้นใย.....	11
2.2 หลักเทคนิคสเปกโทรสโกปี (Spectroscopy).....	12
2.3 วิธีการซัพพอร์ตเวกเตอร์แมชชีน.....	15
2.4 การวัดประสิทธิภาพของโมเดล.....	18
2.5 งานวิจัยที่เกี่ยวข้อง.....	21

บทที่ 3 วิธีดำเนินการวิจัย.....	23
3.1 ส่วนดำเนินการด้านซอฟต์แวร์ที่พัฒนาอัลกอริทึม.....	23
ในการจำแนกสิ่งทอ ตามชนิดผ้าของเส้นใย	23
3.2 ส่วนดำเนินการด้านฮาร์ดแวร์	35
3.3 ส่วนดำเนินการวัดประสิทธิภาพอัลกอริทึมการจำแนก	36
บทที่ 4 ผลการวิจัย.....	42
4.1 ผลการวิจัยส่วนซอฟต์แวร์ที่พัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า	42
4.2 ผลการวิจัยส่วนฮาร์ดแวร์ ที่ดำเนินการพัฒนาต้นแบบเตารีดไฟฟ้าที่ทำความร้อน ด้วยการเหนี่ยวนำแบบกึ่งเรโซแนนท์	71
4.3 ผลการวัดประสิทธิภาพอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า	81
บทที่ 5 บทสรุป.....	86
5.1 สรุปผลการวิจัย.....	86
5.2 อภิปรายผล.....	89
5.3 ข้อเสนอแนะ.....	90
บรรณานุกรม.....	91
ประวัติผู้วิจัย.....	110

สารบัญตาราง

	หน้า
ตาราง 1 อุดมทฤษฎีที่เหมาะสมสำหรับการวัดผ้าแต่ละชนิดเส้นใย.....	12
ตาราง 2 ช่วงความยาวคลื่นของคลื่นรังสีต่าง ๆ.....	13
ตาราง 3 ช่วงรังสีเปกโทรสโคปีอินฟราเรดย่านใกล้ตามระดับพลังงานและการใช้งาน.....	13
ตาราง 4 ซัพพอร์ทเวกเตอร์แมชชีนแบบหนึ่งต่อหนึ่ง.....	17
ตาราง 5 Confusion Matrix แบบ Binary Classification.....	19
ตาราง 6 Confusion Matrix แบบ Multi-class Classification.....	19
ตาราง 7 แสดงตาราง Confusion Matrix แบบ Multi-class Classification	20
ตาราง 8 ซัพพอร์ทเวกเตอร์แมชชีนแบบการตัดแยกที่ละหนึ่งต่อหนึ่ง	33
ตาราง 9 การกำหนดกลุ่มข้อมูลเพื่อสร้างสมการเส้นแบ่งแยกอัลกอริทึมที่นำเสนอ.....	34
ตาราง 10 Confusion Matrix แบบ Multi-class Classification.....	40
ตาราง 11 Confusion Matrix แบบ Multi-class Classification.....	40
ตาราง 12 ผลการทดสอบองค์ประกอบของเส้นใยในผ้าตัวอย่าง	43
ตาราง 13 ผลการจำแนกกลุ่มเส้นใยของผ้าตัวอย่างที่ใช้ทดสอบวิจัย.....	45
ตาราง 14 จำนวนข้อมูลสัญญาณสเปกตรัมสำหรับชุดสอนและทดสอบแบบจำลอง ...	53
ตาราง 15 ข้อมูลความถี่ที่ใช้สร้างเวกเตอร์คุณลักษณะของชุดข้อมูลสอนและ ทดสอบ 60:40.....	58
ตาราง 16 ข้อมูลความถี่ที่ใช้สร้างเวกเตอร์คุณลักษณะของชุดข้อมูลสอนและ ทดสอบ 70:30.....	58
ตาราง 17 ข้อมูลความถี่ที่ใช้สร้างเวกเตอร์คุณลักษณะของชุดข้อมูลสอนและ ทดสอบ 80:20.....	59
ตาราง 18 สมการเส้นแบ่งแยกสำหรับจำแนกประเภทสิ่งทอออกเป็น 3 กลุ่ม.....	66
ตาราง 19 เวกเตอร์ w และค่า b ของสมการเส้นแบ่งแยกสำหรับชุดข้อมูลอัตราส่วน 60:40.....	68

ตาราง 20 เวกเตอร์ w และค่า b ของสมการเส้นแบ่งแยกสำหรับชุดข้อมูลอัตราส่วน 70:30.....	69
ตาราง 21 เวกเตอร์ w และค่า b ของสมการเส้นแบ่งแยกสำหรับชุดข้อมูลอัตราส่วน 80:20.....	69
ตาราง 22 เวกเตอร์ w และค่า b ของสมการเส้นแบ่งแยกกลุ่มข้อมูลแต่ละอัตราส่วน.	70
ตาราง 23 ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นและกำลังไฟฟ้าของวงจร	73
ตาราง 24 Confusion Matrix แบบ Multi-class ของการทดสอบอัตราส่วน 60:40	81
ตาราง 25 Confusion Matrix แบบ Multi-class ของการทดสอบอัตราส่วน 70:30	82
ตาราง 26 Confusion Matrix แบบ Multi-class ของการทดสอบอัตราส่วน 80:20	83
ตาราง 27 ประสิทธิภาพอัลกอริทึมการจำแนกสิ่งทอด้วยชุดข้อมูลทดสอบ อัตราส่วน 60:40	84
ตาราง 28 ประสิทธิภาพอัลกอริทึมการจำแนกสิ่งทอด้วยชุดข้อมูลทดสอบ อัตราส่วน 70:30	84
ตาราง 29 ประสิทธิภาพอัลกอริทึมการจำแนกสิ่งทอด้วยชุดข้อมูลทดสอบ อัตราส่วน 80:20	85

สารบัญภาพ

	หน้า
ภาพ 1 หลักการทำงานของอินเทอร์เน็ตเฟอโรมิเตอร์แบบไม่เคลือบ.....	14
ภาพ 2 ระนาบการตัดสินใจ (Hyperplane) ของ SVM	15
ภาพ 3 การเลือกข้อมูลแบบร้อยละ.....	18
ภาพ 4 การเลือกข้อมูลแบบความเที่ยงตรง K กลุ่ม เมื่อ $K=4$	18
ภาพ 5 ไดอะแกรมการพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าของเส้นใย	24
ภาพ 6 สัญลักษณ์คุณหมุมการวัดผ้าของป้ายการดูแลรักษาผลิตภัณฑ์ผ้า	24
ภาพ 7 การวัดและจัดเก็บข้อมูลประเภทผ้า.....	26
ภาพ 8 ขั้นตอนพัฒนาอัลกอริทึมจำแนกสิ่งทอตามชนิดเส้นใย	29
ภาพ 9 การสร้างสัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัม	30
ภาพ 10 การวิเคราะห์ข้อมูลในโดเมนความถี่เพื่อสกัดคุณลักษณะเด่นสัญญาณ.....	31
ภาพ 11 การสร้างสัญญาณนอร์มอลไลซ์สเปกตรัมของสัญญาณนำเข้าใด ๆ	33
ภาพ 12 อัลกอริทึมการจำแนกสิ่งทอตามชนิดเส้นใยที่นำเสนอ	34
ภาพ 13 ไดอะแกรมการทำงานต้นแบบตัววัดเหนียวนำที่ควบคุมคุณหมุมอัตโนมัติ	35
ภาพ 14 การแบ่งสัดส่วนชุดสอนและชุดข้อมูลทดสอบ	37
ภาพ 15 อัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า	39
ภาพ 16 ตัวอย่างผ้าที่ใช้ในงานวิจัยและจะส่งผลไปทดสอบกับสถาบันผ้า	42
ภาพ 17 ตัวบรรจุและเซนเซอร์ NeoSpectra-Micro	45
ภาพ 18 การเก็บข้อมูลสเปกตรัมของตัวอย่างผ้าบนวัสดุรอง	46
ภาพ 19 เปรียบเทียบสเปกตรัมผ้าตัวอย่างที่ความละเอียดการสแกนต่างกัน	47
ภาพ 20 เปรียบเทียบสเปกตรัมผ้าตัวอย่างที่ความละเอียดการสแกนต่ำสุดและสูงสุด	47
ภาพ 21 สเปกตรัมของผ้าตัวอย่างที่ ณ ตำแหน่งสแกน 10 ตำแหน่ง	48
ภาพ 22 เปรียบเทียบสเปกตรัมตัวอย่างผ้าบนพื้นผิววัสดุที่แตกต่างกัน.....	49
ภาพ 23 สเปกตรัมของตัวอย่างผ้าในกลุ่มเส้นใยธรรมชาติที่มีสีและชนิดแตกต่างกัน.....	50

ภาพ 24	สเปกตรัมของตัวอย่างผ้าในกลุ่มเส้นใยสังเคราะห์ที่มีสีและชนิดแตกต่างกัน.....	51
ภาพ 25	ลำดับข้อมูลสเปกตรัมนำเข้าของตัวอย่างผ้าทดสอบทั้ง 3 กลุ่มเส้นใย	52
ภาพ 26	นอร์มอลไลซ์สเปกตรัมของตัวอย่างผ้าทดสอบทั้ง 3 กลุ่ม	54
ภาพ 27	สัญญาณตัวแทนกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์.....	55
ภาพ 28	ลำดับสัญญาณ RDFT ของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์	56
ภาพ 29	เปรียบเทียบลำดับสัญญาณ RDFT กลุ่มเส้นใยธรรมชาติและเส้นใยสังเคราะห์ ..	57
ภาพ 30	การจำแนกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 60:40	62
ภาพ 31	การจำแนกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 70:30	63
ภาพ 32	การจำแนกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 80:20	65
ภาพ 33	สมการเส้นแบ่งแยกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 60:40.....	66
ภาพ 34	สมการเส้นแบ่งแยกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 70:30.....	67
ภาพ 35	สมการเส้นแบ่งแยกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 80:20.....	67
ภาพ 36	สมการเส้นแบ่งแยกของอัลกอริทึมการจำแนกด้วยวิธีซัพพอร์ตเวกเตอร์ แมชชีน.....	71
ภาพ 37	วงจรเหนี่ยวนำแบบกึ่งเรโซแนนท์ที่ควบคุมการทำงานด้วย ไมโครคอนโทรลเลอร์.....	71
ภาพ 38	ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นขับขา Gate IGBT ที่ความถี่ 21 kHz.....	72
ภาพ 39	ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นขับขา Gate IGBT ที่ความถี่ 30 kHz	72
ภาพ 40	ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นขับขา Gate IGBT ที่ความถี่ 40 kHz	73
ภาพ 41	เปรียบเทียบเซนเซอร์วัดอุณหภูมิของแผ่นพื้นเตารีดที่ใช้ในการทดลอง.....	74

ภาพ 42 เปรียบเทียบเซนเซอร์ที่ใช้ในการวัดอุณหภูมิของแผ่นพื้นเตารีด	75
ภาพ 43 วงจรและต้นแบบเตารีดอัจฉริยะที่ควบคุมอุณหภูมิตามที่กำหนดโดย อัตโนมัติ	77
ภาพ 44 ต้นแบบเตารีดไฟฟ้าอัจฉริยะที่พัฒนา	77
ภาพ 45 หน้าจอ Mobile Application ที่ใช้ในการควบคุมต้นแบบเตารีดอัจฉริยะ	78
ภาพ 46 หน้าจอการทำงานของ Web Application เก็บ Data Log	79
ภาพ 47 ผลการควบคุมอุณหภูมิแผ่นพื้นเตารีดในช่วง 60 °C จนถึง 70 °C	80
ภาพ 48 ผลการควบคุมอุณหภูมิแผ่นพื้นเตารีดในช่วง 75 °C จนถึง 80 °C	80



บทที่ 1

บทนำ

1.1 ความเป็นมาของปัญหา

ในปัจจุบันประเด็นงานวิจัยเกี่ยวกับการจำแนกสิ่งทอตามชนิดของเส้นใยกำลังเป็นที่ได้รับความสนใจทั้งการวิเคราะห์เชิงปริมาณและการวิเคราะห์เชิงคุณภาพในด้านต่าง ๆ อาทิเช่น ด้านอุตสาหกรรมสิ่งทอ ด้านอุตสาหกรรมแฟชั่น ด้านการศึกษาทางวิทยาศาสตร์เกี่ยวกับ มรดกทางวัฒนธรรมหรือธรรมชาติ (Heritage science) โดยเฉพาะอย่างยิ่งในด้านขยะสิ่งทอ (Liu, Li, & Wei, 2020; Mäkelä et al., 2021; Peets, Kaupmees, Vahur, & Leito, 2019) เนื่องจากปัญหาของขยะสิ่งทอจำนวนมากที่ส่งผลกระทบต่อด้านสิ่งแวดล้อม เศรษฐกิจ พลังงาน และการพัฒนาที่ยั่งยืน (Sustainable Development Goals: SDGs) ในอุตสาหกรรมสิ่งทอ ซึ่งปัจจุบันยังมีความต้องการและขาดแคลนเทคโนโลยีที่สามารถจำแนกประเภทสิ่งทอตามชนิดของเส้นใย โดยเฉพาะการจำแนกผ้าผสมที่เป็นประเด็นท้าทายอย่างมาก เพื่อให้สามารถเทคโนโลยี การจำแนกไปใช้งานร่วมกับระบบอัตโนมัติในกระบวนการคัดแยกประเภทสิ่งทอก่อนการรีไซเคิล ทำให้ช่วยแก้ปัญหาด้านเวลา ต้นทุน และประสิทธิภาพ รวมถึงสามารถนำไปประยุกต์ใช้ในอุตสาหกรรมอิเล็กทรอนิกส์อัจฉริยะ ซึ่งเป็นอุตสาหกรรมเป้าหมายหลักที่มีความสำคัญต่อเศรษฐกิจของประเทศไทยที่ต้องการเป็นผู้นำในการผลิตชิ้นส่วนอิเล็กทรอนิกส์ สำหรับอุปกรณ์เครื่องใช้ไฟฟ้า รถยนต์ อุปกรณ์เครื่องใช้ภายในบ้านที่มีความซับซ้อน โดยงานวิจัยนี้เน้นไปที่เครื่องใช้ไฟฟ้าอัจฉริยะ ที่สามารถนำองค์ความรู้เกี่ยวกับการจำแนกสิ่งทอตามชนิดของเส้นใยผ้าไปใช้ร่วมกัน ได้แก่ “เตารีดไฟฟ้าอัจฉริยะ” ในมิติของการประหยัดพลังงาน และการถนอมสิ่งทอ จึงสรุปประเด็นปัญหาต่าง ๆ ดังนี้

1.1.1. ด้านขยะสิ่งทอและการรีไซเคิลสิ่งทอ

กระแสแฟชั่นมีบทบาทต่อพฤติกรรมและการแต่งกายของคนทั่วโลก ทำให้อุตสาหกรรมเสื้อผ้าทั่วโลกพัฒนาขึ้นอย่างรวดเร็วเพื่อตอบสนองความต้องการในการบริโภคจากปี พ.ศ. 2543 ที่ผลิตเสื้อผ้าประมาณ 50,000 ล้านชิ้นต่อปี แต่ปัจจุบันผลิตมากกว่า 150,000 ล้านชิ้นต่อปี ส่งผลให้อุตสาหกรรมสิ่งทอสร้างมลพิษมากที่สุดเป็นอันดับ 2 ของโลก รองจากอุตสาหกรรมน้ำมัน โดยเฉพาะในกระบวนการผลิตถูกระบุว่า ปล่อยก๊าซคาร์บอนไดออกไซด์สูงถึง 1.2 พันล้านตันต่อปี และสร้างปัญหาน้ำเสียถึง 20% ของอุตสาหกรรมทั้งหมดในโลกรวมกัน รวมถึงปัญหา ด้านขยะสิ่งทอจำนวนมากที่เพิ่มขึ้นเนื่องจาก 10% ของเสื้อผ้าที่ผลิตได้ทั้งหมดในแต่ละปี จะค้างในสต็อกหรือถูกเก็บไว้ในโกดังสินค้าไม่ได้ถูกนำออกมาจำหน่าย ส่วนอีก 75% ถูกจำหน่ายในท้องตลาดและกลายเป็นขยะใน

ที่สุด มีเพียง 15% เท่านั้นที่สามารถนำกลับมารีไซเคิลได้ โดยเฉพาะในประเทศจีนที่ต่อปีมีขยะจากเสื้อผ้าเก่าประมาณ 26 ล้านตัน และมีเพียง 1% เท่านั้น ที่สามารถนำไปรีไซเคิลได้ทำให้บริษัทเสื้อผ้าและเครื่องนุ่งห่มทั่วโลก หรือ องค์กรไม่แสวงหาผลกำไร เช่น FABSCRAP ตระหนักถึงผลกระทบต่อสิ่งแวดล้อม จึงเริ่มที่จะนำขยะสิ่งทอซึ่งเกิดจากเศษผ้าหรือเสื้อผ้าเก่าไปรีไซเคิลตามชนิดของเส้นใย เพื่อนำมาคัดแยกผ้าแต่ละชนิด เช่น ผ้าขนสัตว์ ผ้าฝ้าย 100% จะถูกนำไปผลิตเป็นผ้าใหม่ ส่วนกลุ่มผ้าที่เป็นเส้นใยผสมจะนำไปย่อยเพื่อผลิตเป็นแผ่นฉนวน ผ้าห่ม หรือพรม และกลุ่มที่เป็นเส้นใยสังเคราะห์จะถูกนำไปทิ้ง เพราะไม่สามารถรีไซเคิลได้ (กรมส่งเสริมคุณภาพสิ่งแวดล้อม, 2564) ทำให้การรีไซเคิลขยะสิ่งทอหรือเสื้อผ้าที่ใช้แล้วในอุตสาหกรรมสิ่งทอกำลังเป็นประเด็นที่กำลังได้รับความสนใจเป็นอย่างมากในปัจจุบัน เนื่องจากเป็นส่วนหนึ่งของการพัฒนาที่ยั่งยืน (Sustainable Development Goals: SDGs) และปรับเปลี่ยนสู่ความเป็นเศรษฐกิจหมุนเวียน (Circular Economy) สอดคล้องกับข้อมูลที่สภายุโรปได้รายงาน เมื่อวันที่ 29 ธันวาคม 2563 เกี่ยวกับการเสนอร่างแผนยุทธศาสตร์ด้านสิ่งทอที่ยั่งยืน

เพื่อลดผลกระทบต่อสิ่งแวดล้อมที่เกิดขึ้นจากภาคอุตสาหกรรมสิ่งทอ ทั้งที่เกิดขึ้นจากกระบวนการผลิตและการฝังกลบของขยะสิ่งทอ โดยในกระบวนการผลิตจำเป็นต้องใช้วัตถุดิบและน้ำสูงเป็นอันดับ 4 จากภาคอุตสาหกรรมทั้งหมด อันเนื่องจากการเกษตรในการปลูกต้นฝ้ายและเส้นใยอื่น ๆ ทำให้การผลิตเสื้อยืดหนึ่งตัวต้องใช้น้ำมากถึง 2,700 ลิตร และเกิดการปล่อยก๊าซเรือนกระจกมากเป็นลำดับที่ 5 หรือประมาณร้อยละ 10 ซึ่งมีปริมาณมากกว่าก๊าซคาร์บอนจากภาคอุตสาหกรรมบินระหว่างประเทศและการขนส่งทางทะเลรวมกัน ในส่วนของการฝังกลบขยะสิ่งทอ พบว่า ชาวยุโรปหนึ่งคนใช้สิ่งทอประมาณ 26 กิโลกรัมและทิ้งประมาณ 11 กิโลกรัมต่อปี ทำให้ 87% ของเสื้อผ้าทั้งหมดที่ใช้แล้ว ถูกนำไปเผาหรือฝังกลบ ซึ่งจากสถิติปี 2017 รายงานว่า ทั่วโลกมีการรีไซเคิลขยะสิ่งทอได้เพียงร้อยละ 1 เท่านั้น ซึ่งคาดว่าสาเหตุส่วนใหญ่มาจากการไม่มีเทคโนโลยีที่เพียงพอ (กรองยุโรปเพื่อไทย, 2564) ซึ่งสอดคล้องกับงานวิจัยของ ดูร์ และคณะ (Du et al., 2022) ที่ได้กล่าวถึงปัญหาของจำนวนขยะสิ่งทอที่มีมากถึง 150 ล้านตันต่อปีซึ่งตามทฤษฎีแล้วขยะสิ่งทอเหล่านี้สามารถรีไซเคิลได้ถึง 95% แต่ในเชิงปฏิบัติแล้วทำได้ในอัตราที่ต่ำมาก อาทิเช่น ในประเทศจีน 10-15% ในประเทศอเมริกา 15% และ 25% ในสหภาพยุโรป ซึ่งสาเหตุหลักเกิดจากประสิทธิภาพและความเร็วในการจำแนกส่วนประกอบเส้นใยของสิ่งทอ คณะวิจัยจึง ทำการพัฒนาการจดจำชนิดของผ้าเพื่อใช้ในระบบคัดแยกขยะสิ่งทออัตโนมัติบนพื้นฐานเทคนิคสเปกโทรสโกปีอินฟราเรดย่านใกล้ในช่วงความยาวคลื่น 901 ถึง 2,500 นาโนเมตร ด้วยการแปลงข้อมูลเป็นภาพขาวดำขนาด 40x40 พิกเซล และใช้โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) บนแพลตฟอร์ม Baidu Deep Learning ในการสร้างแบบจำลองเพื่อจำแนกผ้า จำนวน 13 ชนิด รวม 2,764 ตัวอย่าง โดยแบ่งเป็นข้อมูลเทรนและทดสอบในอัตราส่วน 70:30 ผลวิจัยพบว่า แบบจำลองมีความ

ถูกต้องในการจำแนกรวม 95.4% และใช้เวลาจำแนกและคัดแยกน้อยกว่า 2 วินาที ซึ่งแสดงให้เห็นว่า การพัฒนาระบบจำแนกสิ่งทอช่วยแก้ปัญหาคอขวดที่เกิดขึ้นในกระบวนการรีไซเคิลขยะสิ่งทอได้ จากปัญหาดังกล่าวแสดงให้เห็นถึงความต้องการงานวิจัย นวัตกรรม และเทคโนโลยีในการคัดแยกขยะสิ่งทอตามชนิดเส้นใยที่มีประสิทธิภาพและรวดเร็ว รวมถึงประเด็นความท้าทายในการคัดแยกสิ่งทอที่เกิดจากเส้นใยผสม เพื่อแก้ปัญหาคอขวดที่เกิดขึ้นในขั้นตอนการคัดแยกอย่างอัตโนมัติก่อนกระบวนการรีไซเคิล เป็นประเด็นที่ได้รับความสนใจจากกลุ่มนักวิจัย และมีการใช้ร่วมกับเมธอดในการวิเคราะห์ หรือจำแนกที่หลายหลายดังนี้

ริบา และคณะ (Riba, Cantero, Riba-Mosoll, & Puig, 2022) ได้กล่าวถึง ผลกระทบต่อสิ่งแวดล้อมที่เกิดขึ้นจากอุตสาหกรรมสิ่งทอและความต้องการเปลี่ยนแปลงเข้าสู่เศรษฐกิจหมุนเวียน จึงจำเป็นต้องเพิ่มปริมาณการรีไซเคิลสิ่งทอนำกลับมาใช้ใหม่ แต่ประเด็นปัญหาเรื่องการคัดแยกสิ่งทอที่ปัจจุบันยังใช้แรงงานคน ซึ่งมีต้นทุนสูงและไม่สามารถคัดแยกสิ่งทอจำนวนมากได้ ระบบคัดแยกอัตโนมัติจึงมีความจำเป็น งานวิจัยนี้จึงนำเสนอการคัดแยกสิ่งทอโดยใช้ข้อมูลสเปกตรัมจากเครื่อง ATR-FTIR สเปกโตรมิเตอร์ และลดจำนวนตัวแปรโดยใช้เทคนิคการวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis: PCA) ร่วมกับการวิเคราะห์ตัวแปรคานอนิคอล (Canonical Variates Analysis: CVA) และใช้ตัวแปรที่ลดจำนวนและวิเคราะห์ในการจำแนกประเภทของสิ่งทอด้วยอัลกอริทึม K-Nearest Neighbor Algorithm (K-NN)

คูลาและคณะ (Cura, Rintala, Kamppuri, Saarimäki, & Heikkilä, 2021) ได้กล่าวแสดงให้เห็นถึงการแยกประเภทหรือส่วนประกอบของเส้นใยสิ่งทอให้ถูกต้อง ประหยัดเวลาและมีประสิทธิภาพเพียงพอ สำหรับการจำแนกและคัดแยกอย่างอัตโนมัติก่อนกระบวนการรีไซเคิลยังเป็นอีกหนึ่งประเด็นสำคัญที่ซึ่งปัญหาของวิธีการดั้งเดิมในการคัดแยกต้องใช้เวลาและแรงงานคนเพื่อคัดแยกขยะสิ่งทอจากฉลากผลิตภัณฑ์ แต่ปัญหาที่พบ คือ ฉลากไม่มีหรือสูญหาย และร้อยละ 41 ของฉลากบนผลิตภัณฑ์สิ่งทอทั้งหมดที่เป็นผ้าผสมบอกได้ไม่ถูกต้อง จึงทำพัฒนาระบบการจำแนกด้วยเทคนิคสเปกโทรสโกปีอินฟราเรดย่านใกล้ โดยทดสอบกับตัวอย่างสิ่งทอ ที่ใช้แล้ว 74 ตัวอย่าง ยังไม่ผ่านการใช้ 179 ตัวอย่าง และไม่ผ่านการซักหรือเตรียมตัวอย่างใด ๆ เพื่อจำลองให้เหมือนในสถานที่คัดแยกขยะสิ่งทอ ผลการวิจัยพบว่า มีความผิดพลาดเกิดขึ้นเนื่องจากสิ่งทอเป็นผ้าผสมและอัตราส่วนที่หลากหลาย หรือ มีส่วนประกอบเดียว เช่น cotton 100% หรือ polyester 100% ผิดพลาดอันเนื่องมาจากผลกระทบของคุณสมบัติโครงสร้างผ้า อาทิเช่น ผ้าที่ถักหลวม ผ้าบาง หรือ ผลกระทบจากเปลี่ยนแปลงโครงสร้างทางเคมีของโพลีเมอร์ เช่น การเสื่อมสภาพจากการใช้งานและการรีด

ริบาและคณะ (Riba et al., 2022) ได้กล่าวถึง ความต้องการของเมธอดที่ดีในการจำแนกประเภทสิ่งทอเพื่อให้ได้กระบวนการรีไซเคิลสิ่งทอที่มีคุณภาพ ซึ่งปัจจุบันใช้แรงงานคนทำให้มีต้นทุนทรัพยากรมนุษย์ที่สูงและไม่เป็นระบบอัตโนมัติ ดังนั้นจึงไม่สามารถจัดการขยะจำนวนมากใน

แต่ละวันได้ จึงทำการพัฒนาระบบคัดแยกขยะสิ่งทอที่สามารถนำไปใช้ในได้ในทางอุตสาหกรรมเพื่อระบุว่าเป็นเส้นใยชนิดเดียว (เส้นใยธรรมชาติหรือเส้นใยสังเคราะห์ 100%) หรือเส้นใยผสม จากข้อมูลสเปกตรัมอินฟราเรดย่านใกล้ในช่วงความยาวคลื่น 1,100 ถึง 2,200 นาโนเมตร เพื่อลดผลกระทบจากสัญญาณรบกวนและหลีกเลี่ยงการใช้คลื่นแสงในย่านที่ตามองเห็น (visible light) แล้วทำการหาค่าเฉลี่ยสเปกตรัมจากการสแกน 32 ครั้ง ทำให้ได้ 2,201 ข้อมูลต่อสเปกตรัม โดยแบ่งการทดสอบออกเป็น 3 กรณีศึกษา คือ กลุ่มผ้าตัวอย่างชนิดเส้นใยชนิดเดียว จำนวน 210 ตัวอย่าง กลุ่มที่สองใช้ผ้า กลุ่มตัวอย่างเส้นใยผสม (Viscose/PE) จำนวน 73 ตัวอย่าง และกลุ่มตัวอย่างเส้นใยผสม (Cotton/PE) จำนวน 90 ตัวอย่าง นำไปแบ่งเป็นข้อมูลเทรนและทดสอบในอัตราส่วน 50:50 ผลการวิจัยพบว่า การใช้เมธอดการวิเคราะห์องค์ประกอบหลัก (PCA) ร่วมกับการวิเคราะห์ตัวแปรคานอนิคอล (Canonical Variates Analysis: CVA) ในการลดจำนวน ตัวแปรลงเหลือเพียง 6 ตัวแปรก่อนใช้โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ในการจำแนกให้ผลความถูกต้อง 100% ในกลุ่มเส้นใยเดี่ยว และให้ความถูกต้อง 90-100% สำหรับกลุ่มเส้นใยผสม

1.1.2. ด้านอุตสาหกรรมอิเล็กทรอนิกส์อัจฉริยะและเครื่องใช้ไฟฟ้าอัจฉริยะ

อุตสาหกรรมอิเล็กทรอนิกส์มีความสำคัญต่อโลกมากขึ้น เนื่องจากกระแสการเปลี่ยนแปลงที่รวดเร็ว ทำให้ความต้องการของผู้บริโภคนั้นเปลี่ยนแปลงไปต้องการให้เครื่องใช้ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ที่สามารถทำงานได้หลายหลายฟังก์ชัน ใช้งานง่าย ช่วยอำนวยความสะดวก ลดระยะเวลาในการทำงาน และมีประสิทธิภาพ ทำให้ผู้ผลิตทั่วโลก จึงเน้นไปวิจัยและพัฒนาอุปกรณ์อิเล็กทรอนิกส์ที่สามารถควบคุมกระบวนการทำงานของอุปกรณ์อื่น ๆ ที่จะนำไปสู่การลดปริมาณการใช้พลังงานลง ซึ่งสอดคล้องภาวะการขาดแคลนพลังงานที่จะเกิดขึ้นในอนาคต โดยในประเทศไทยอุตสาหกรรมอิเล็กทรอนิกส์อัจฉริยะ (Smart Electronics) เป็นหนึ่งในอุตสาหกรรม First S-Curve ซึ่งหมายถึง อุตสาหกรรมที่ประเทศไทยมีศักยภาพและความเชี่ยวชาญในการผลิตสามารถสร้างมูลค่าทางเศรษฐกิจจำนวนมากแต่ขาดการพัฒนา ต่อยอดด้วยเทคโนโลยีสมัยใหม่ ที่เป็นยุทธศาสตร์หนึ่งภายใต้แผนนโยบายการขับเคลื่อนประเทศไทย 4.0 ที่จะช่วยส่งผลการเจริญเติบโตทางเศรษฐกิจในระยะสั้นและระยะกลาง เพื่อก้าวพ้นกับดักรายได้ประเทศปานกลางสู่ประเทศรายได้สูง ซึ่งกลุ่มเครื่องใช้ไฟฟ้าในบ้าน (Electrics for Home-use) เป็น 1 ใน 5 อุตสาหกรรมเครื่องใช้ไฟฟ้าและอิเล็กทรอนิกส์ของไทย ที่ควรมุ่งเน้นไปที่การวิจัยและพัฒนาเซนเซอร์ (Sensor) ไมโครอิเล็กทรอนิกส์ (Microelectronic) สมอกล (Artificial Intelligence) อินเทอร์เน็ตในทุกสิ่ง (Internet of Things) และอุปกรณ์อัจฉริยะ (Smart Device) เพื่อสร้างความได้เปรียบในการแข่งขันและพัฒนาสู่อุตสาหกรรมใหม่ในอนาคต (New S-Curve) โดยอิเล็กทรอนิกส์อัจฉริยะ สามารถนิยามได้ว่า คือ อุปกรณ์เครื่องใช้ไฟฟ้าต่าง ๆ ที่ติดตั้ง ระบบสมองกลฝังตัว เพื่อให้มีคุณสมบัติใหม่ ๆ (สถาบันทรัพย์สินทาง

ปัญญาแห่งจุฬาลงกรณ์มหาวิทยาลัย, 2560) และสอดคล้องกับเงื่อนไขของการผลิตเครื่องใช้ไฟฟ้าอัจฉริยะ (Smart Electrical Appliances) ของประกาศคณะกรรมการส่งเสริมการลงทุน พ.ศ.2562 ที่ระบุว่า เครื่องใช้ไฟฟ้าอัจฉริยะต้องมีคุณสมบัติ คือ มีชิ้นส่วนอิเล็กทรอนิกส์ ซึ่งสามารถตรวจจับและรับข้อมูลได้เป็นองค์ประกอบหลัก รวมถึงมีระบบปฏิบัติการหรือประมวลผลฝังตัวอยู่ในตัวอุปกรณ์หรือเครื่องมือนั้น ๆ

1.1.3. ด้านประสิทธิภาพและการประหยัดพลังงานไฟฟ้า

การขยายตัวของสังคมและการเจริญเติบโตของเศรษฐกิจไทย ส่งผลให้ความต้องการไฟฟ้าของประเทศสูงขึ้น ดังนั้นการจัดการด้านการใช้ไฟฟ้า (Demand Side Management:DSM) จึงเป็นภารกิจที่คณะรัฐมนตรีอนุมัติให้ การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) ดำเนิน การรณรงค์ส่งเสริมให้ประชาชนใช้ไฟฟ้าอย่างประหยัดและมีประสิทธิภาพด้วยโครงการ “ฉลากประหยัดไฟฟ้าเบอร์ 5” ซึ่งการใช้ไฟฟ้าในครัวเรือนคิดเป็นร้อยละ 25 ของปริมาณการใช้ไฟฟ้าทั้งประเทศ จึงควรส่งเสริมให้ทุกครัวเรือนเปลี่ยนมาใช้อุปกรณ์ไฟฟ้าที่มีประสิทธิภาพสูง รวมถึงผลักดันให้ผู้ประกอบการผลิตอุปกรณ์ไฟฟ้าที่มีประสิทธิภาพสูงและประหยัดไฟฟ้า (กองส่งเสริมประสิทธิภาพอุปกรณ์ไฟฟ้า การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย, 2558)

รายงานของ การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย พบว่า เตารีดไฟฟ้าทั้งแบบแห้งหรือไอน้ำ เป็นเครื่องใช้ไฟฟ้าในครัวเรือนที่ใช้ปริมาณไฟฟ้ามากที่สุดเป็นอันดับที่ 2 รองจาก เครื่องทำน้ำอุ่นไฟฟ้า โดยใช้กำลังไฟฟ้าที่ 1,000 – 2,600 วัตต์ (การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย, 2565)และเตารีดไฟฟ้าแบบแห้งเป็นนิยมใช้มากที่สุดในปัจจุบัน เพราะมีราคาถูกและ ใช้งานง่าย โดยมีส่วนประกอบที่สำคัญ 3 ส่วน คือ ไส้เตารีดที่ทำจากลวดนิโครมทำหน้าที่กำเนิด ความร้อน เทอร์โมสแตท (Thermostat) ทำหน้าที่ควบคุมระดับความร้อน และแผ่นพื้นเตารีดทำจากโลหะไม่เป็นสนิมหรืออลูมิเนียม ซึ่งกระทรวงพลังงานได้แนะนำการใช้อย่างถูกวิธีและประหยัดพลังงานไว้อย่างน่าสนใจ คือ ควรรีดผ้าที่ระดับความร้อนที่เหมาะสมกับความหนาและชนิดของผ้า โดยรีดผ้าที่ต้องความร้อนน้อยก่อน แล้วจึงรีดผ้าที่ต้องการความร้อนสูง และควรถอดปลั๊กก่อนสิ้นสุดการรีดผ้าประมาณ 3 – 4 นาที เพื่อรีดผ้าที่ต้องการความร้อนน้อยไว้ตอนท้าย ตามปกติ เตารีดจะมีการตั้งตัวควบคุมความร้อนจากน้อยไปมากตามชนิดของผ้างดังนี้ ชนิดกลุ่มผ้าอะคริลิก ชนิดกลุ่มผ้าไนลอน ชนิดกลุ่มผ้าเรยอนและโพลีเอสเตอร์ ชนิดกลุ่มผ้าขนสัตว์ ชนิดกลุ่มผ้าฝ้าย และชนิดกลุ่มผ้าลินิน ซึ่งวิธีการดังกล่าวจะช่วยให้เตารีดขนาด 1,000 วัตต์ สามารถประหยัดไฟฟ้า ลดลง 0.3 กิโลวัตต์ชั่วโมง ดังนั้นหากทั่วประเทศไทยมี 12 ล้านครัวเรือนจะช่วยประหยัดไฟฟ้าถึง 3.6 ล้านกิโลวัตต์ชั่วโมง หรือคิดเป็นมูลค่า 36 ล้านบาทต่อเดือน หรือ 432 ล้านบาทต่อปี โดยคิดที่อัตราค่าไฟฟ้าเฉลี่ยที่ 2.5 บาทต่อหน่วย (จินดา แก้วเขียว, 2563) จากปัญหาดังกล่าวแสดงให้เห็นว่า วิธีการให้ความร้อนของเตารีดไฟฟ้าแบบเดิมมีการสูญเสีย

พลังงานหรือใช้พลังงานไฟฟ้าไม่มีประสิทธิภาพ จึงเป็นประเด็นที่ได้รับความสนใจจากกลุ่มนักวิจัยในการศึกษาวิธีการให้ความร้อนแก่เตารีดด้วยวิธีการให้ความร้อนแบบเหนี่ยวนำสนามแม่เหล็กไฟฟ้า ดังนี้

อนันต์ โสภิน & เฉลิมชนม์ ตั่งวชิรพันธุ์ (2553) ที่ต้องการพัฒนาการให้ความร้อนแก่เตารีดไฟฟ้าที่อาศัยหลักการให้ความร้อนแบบเหนี่ยวนำสนามแม่เหล็กไฟฟ้า โดยใช้มอสเฟตเป็นอุปกรณ์ในการสวิตช์ ผลวิจัยพบว่า ที่ความถี่เรโซแนนซ์ 35 กิโลเฮิรซ์ เตารีดไฟฟ้าที่พัฒนาใช้พลังงานไฟฟ้าน้อยมากกว่าเตารีดไฟฟ้าแบบปกติ 5 เท่า สำหรับการให้อุณหภูมิที่เท่ากัน แต่พบปัญหาด้านการเสียหายของอุปกรณ์มอสเฟตและวงจรควบคุมเกิดขึ้นโดยง่าย นอกจากนี้ ยังเสนอแนะเกี่ยวกับการพัฒนาระบบควบคุมความร้อนให้คงที่และความสามารถในการปรับอุณหภูมิได้ละเอียดมากขึ้น

Sanajit & Jangwanitlert (2011) ได้วิจัยพัฒนาเตารีดไฟฟ้าด้วยการเหนี่ยวนำความร้อนแบบฮาฟบริดจ์ (Series-Resonant Half-Bridge Inverter) ที่ควบคุมโดยการปรับเปลี่ยน ค่าความกว้างของลูกคลื่น แต่การกำหนดความถี่สัญญาณคงที่เพื่อลดสัญญาณรบกวนจาก คลื่นแม่เหล็กไฟฟ้าและหลีกเลี่ยงเสียงรบกวนจากความถี่ ผลวิจัยพบว่า ระยะเวลาในการทำ ความร้อนถึงจุดอุณหภูมิสูงสุด ที่ 90 °C และระยะเวลาในการคายความร้อนให้ลดต่ำลงถึงอุณหภูมิต่ำสุดที่ 30 °C จะเพิ่มมากขึ้นตามความหนาของแผ่นพื้นเตารีดที่ใช้เหนี่ยวนำ และเมื่อทดสอบโดยใช้แผ่นพื้นหนา 4 มม. เพื่อเปรียบเทียบการใช้พลังงานไฟฟ้ากับเตารีดแบบเดิม พบว่า เตารีดไฟฟ้าด้วยการเหนี่ยวนำใช้พลังงานไฟฟ้า 0.092 kW/h ในขณะที่เตารีดไฟฟ้าแบบเดิมใช้ 0.117 kW/h แสดงให้เห็นว่ามีประสิทธิภาพการใช้พลังงานที่ 92% และลดการใช้พลังงานไฟฟ้าลงครึ่งหนึ่ง

เฉลิมชนม์ ตั่งวชิรพันธุ์, จักรรินทร์ ไพโรจน์พัฒนกุล, สุวิชา เกิดดี, บรรเจิด เจริญพันธ์ & อติศร แก้วกิติ (2557) ทำการศึกษาการกระจายความร้อนบนแผ่นพื้นเตารีดให้ ความร้อนแบบเหนี่ยวนำสนามแม่เหล็กไฟฟ้า ที่ออกแบบขดลวดในแบบ pancake ที่มีค่าขดลวด 100 μ H และ ใช้วงจรฮาฟบริดจ์คอนเวอร์เตอร์ในการควบคุมความถี่ 20 kHz โดยทำเปรียบเทียบการใช้พลังงานและอุณหภูมิจำนวน 17 ตำแหน่งเปรียบเทียบกับเตารีดไฟฟ้าขนาด 1000 วัตต์ พบว่า แผ่นพื้นเตารีดที่ให้ ความร้อนแบบเหนี่ยวนำสนามแม่เหล็กไฟฟ้ามีการกระจายความร้อนใกล้เคียงกับเตารีดไฟฟ้าและ ประหยัดพลังงานมากกว่า 2.8 เท่า

คมกฤษณ์ ศรีสุวรรณ & จีรพงศ์ ศรีวิชัย (2560) ทำการทดสอบใช้เตาแม่เหล็กไฟฟ้า ร่วมกับเตารีดที่สร้างขึ้นจากแผ่นโลหะในการรีดผ้าฝ้ายและฝ้ายีนจำนวนชนิดละ 10 ชั้นเป็นเวลา 30 นาที เพื่อเปรียบเทียบกับเตารีดไฟฟ้าแบบปกติ พบว่า เตารีดเหนี่ยวนำสามารถลดการใช้พลังงานไฟฟ้าลงได้ 3 Wh และ 7 Wh จากการรีดผ้าฝ้ายและฝ้ายีนตามลำดับ และให้ความร้อนอุณหภูมิสูงสุดที่ 250 องศาเซลเซียส

จากประเด็นปัญหาทั้ง 3 ด้านดังกล่าว แสดงให้เห็นถึงความสำคัญในการพัฒนา อัลกอริทึมสำหรับจำแนกสิ่งทอ โดยเฉพาะในด้านขยะสิ่งทอและการรีไซเคิลสิ่งทอที่มีส่งผลกระทบต่อ หลายด้านทั้งสิ่งแวดล้อม เศรษฐกิจ พลังงาน และการพัฒนาที่ยั่งยืน ซึ่งงานวิจัยส่วนใหญ่จะใช้ เทคนิคสเปกโทรสโกปีอินฟราเรดย่านใกล้ (NIR) ในการจำแนกสิ่งทอเนื่องจากเป็นเทคนิคที่ให้ผลที่ วิเคราะห์ขององค์ประกอบทางเคมีที่แม่นยำโดยไม่ทำลายตัวอย่าง และรวดเร็วกว่าการใช้วิธีการ วิเคราะห์ทางเคมีในห้องปฏิบัติการ แต่ส่วนใหญ่จำเป็นต้องใช้เครื่องสเปกโตรมิเตอร์ ระดับ ห้องปฏิบัติการ และต้องมีกระบวนการจัดเตรียมข้อมูล หรือ การสกัดคุณลักษณะ เช่น PCA หรือ LDA เพื่อลดจำนวนมิติข้อมูล ร่วมกับเมธอดการจำแนกที่หลายหลายซึ่งส่วนใหญ่ใช้ทรัพยากรในการ ประมวลผลสูง อาทิเช่น Extreme Learning Machine หรือ โครงข่ายประสาทแบบคอนโวลูชัน เป็นต้น ดังนั้นหากสามารถพัฒนาอัลกอริทึมสำหรับจำแนกสิ่งทอโดยไม่จำเป็นต้องใช้ เครื่องสเปกโตรมิเตอร์ ระดับห้องปฏิบัติการและสามารถทำงานบนระบบสมองกลฝังตัวซึ่งไม่มีทรัพยากรในการประมวลผลที่ สูงมาก จึงเป็นประเด็นงานวิจัยที่ท้าทายและสามารถนำไปต่อยอดพัฒนาเครื่องใช้ไฟฟ้าอัจฉริยะที่จะ ช่วยส่งผลต่อการเจริญเติบโตทางเศรษฐกิจในระยะสั้นและระยะกลาง เพื่อก้าวพ้นกับดักรายได้ประเทศ ปานกลางสู่ประเทศรายได้สูง ซึ่งกลุ่มเครื่องใช้ไฟฟ้าในบ้าน (Electrics for Home-use) เป็น 1 ใน 5 อุตสาหกรรมเครื่องใช้ไฟฟ้าและอิเล็กทรอนิกส์ของไทย ที่ควรมุ่งเน้น โดยเฉพาะเตารีดไฟฟ้าซึ่งเป็น เครื่องใช้ไฟฟ้าในครัวเรือนที่มีการใช้ปริมาณไฟฟ้ามากที่สุดเป็นอันดับที่ 2 ซึ่งการใช้ความร้อนที่ เหมาะสมกับผ้าแต่ละชนิดจะเป็นการช่วยประหยัดพลังงานไฟฟ้าได้ทางหนึ่ง ทำให้แสดงถึงประเด็น ปัญหาที่สามารถนำผลลัพธ์จากการพัฒนาอัลกอริทึมในการจำแนกประเภทของสิ่งทอมาใช้แก้ปัญหา ได้บนการพัฒนาเครื่องใช้ไฟฟ้าที่อำนวยความสะดวกให้กับผู้ใช้นอกจากนี้การเปลี่ยนองค์ประกอบของ เตารีด อย่างขดลวดต้านและวัสดุแผ่นพื้นที่ทำหน้าที่สร้างความร้อนให้สามารถประยุกต์ใช้หลักการให้ ความร้อนแบบเหนี่ยวนำสนามแม่เหล็กไฟฟ้าจะช่วยเพิ่มประสิทธิภาพการใช้พลังงานได้

จากประเด็นปัญหาทั้ง 3 ด้านดังกล่าว ผู้วิจัยจึงมีวัตถุประสงค์ที่จะพัฒนาอัลกอริทึมในการ จำแนกสิ่งทอตามชนิดเส้นใยออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และ กลุ่มผ้าเส้นใยผสม บนพื้นฐานข้อมูลสเปกตรัมในย่านใกล้อินฟราเรด และใช้ผลลัพธ์จากจำแนกเป็น สัญญาณนำเข้าไปให้เตารีดไฟฟ้าอัจฉริยะที่มีระบบควบคุมอุณหภูมิที่เหมาะสมกับผ้าแต่ละชนิดด้วย การให้ความร้อนแบบเหนี่ยวนำสนามแม่เหล็กไฟฟ้า

1.2 จุดมุ่งหมายของการวิจัย

1.2.1. เพื่อพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าเส้นใยผสม บนพื้นฐานข้อมูลสเปกตรัม ในย่านใกล้อินฟราเรด (Near Infrared) ช่วงความยาวคลื่น 1,350 ถึง 2,500 นาโนเมตร

1.2.2. เพื่อหาประสิทธิภาพของอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยออกเป็น 3 กลุ่มคือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าเส้นใยผสม บนพื้นฐานข้อมูลสเปกตรัมในย่านใกล้อินฟราเรด (Near Infrared) ช่วงความยาวคลื่น 1,350 ถึง 2,500 นาโนเมตร

1.2.3. เพื่อประยุกต์ใช้อัลกอริทึมที่พัฒนาขึ้นสำหรับจำแนกสิ่งทอตามชนิดของเส้นใยในระบบควบคุมอุณหภูมิที่เหมาะสมของสิ่งทอตามชนิดของเส้นใย ของเตารีดไฟฟ้าเหนี่ยวนำความร้อนด้วยแม่เหล็กไฟฟ้าที่พัฒนาขึ้น

1.3 ขอบเขตของการวิจัย

1.3.1. สิ่งทอที่ใช้ทดสอบในงานวิจัยเป็นผ้าผืนที่นิยมใช้ในการตัดเย็บเสื้อผ้าจากโรงงานหรือแหล่งจำหน่ายผ้าในประเทศไทย ซึ่งแบ่งออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าผสม ที่มีสัดส่วนของเส้นใยธรรมชาติและเส้นใยสังเคราะห์ ในอัตราส่วนที่แตกต่างกันไป โดยอ้างอิงผลการทดสอบปริมาณสัดส่วนชนิดเส้นใยตามมาตรฐาน มอก.121 เล่ม 26:2552 (Thai Industrial Standard: TIS, Standards No.121 part 26-2552) ที่ว่าด้วยวิธีทดสอบหาปริมาณของเส้นใย 2 ชนิด ที่ผสมกันของผลิตภัณฑ์สิ่งทอ โดยกำหนดเครื่องมือ สารเคมีและวิธีเตรียมการชักตัวอย่าง และการเตรียมตัวอย่าง จากศูนย์วิเคราะห์ทดสอบสิ่งทอ สถาบันพัฒนาอุตสาหกรรมสิ่งทอแห่งประเทศไทย

1.3.2. ข้อมูลสเปกตรัมได้จากเซนเซอร์สเปกตรัม NeoSpectra-Micro รุ่น SWS62231 ของบริษัท Si-Ware System ประเทศอียิปต์ ที่ทำงานบนพื้นฐานเทคโนโลยีฟูเรียร์ทรานซ็องฟอร์มอินฟราเรดสเปกโตรมิเตอร์ (Fourier Transform Infrared Spectrometer) และมีค่าการดูดกลืนแสงที่อยู่ในย่านใกล้อินฟราเรด (Near Infrared) ในช่วงความยาวคลื่นในช่วง 1350 ถึง 2500 นาโนเมตร ที่มีจำนวน 65 ข้อมูลต่อสเปกตรัม

1.4 นิยามศัพท์เฉพาะ

1.4.1. เส้นใย (fibers) คือ วัสดุหรือสารใด ๆ ทั้งที่เกิดจากธรรมชาติและมนุษย์สร้างขึ้น มีลักษณะเป็นเส้นยาวและบาง อัตราส่วนระหว่างความยาวต่อเส้นผ่านศูนย์กลางเท่ากับหรือมากกว่า 100 เท่า สามารถขึ้นรูปเป็นผ้าได้และต้องเป็นองค์ประกอบที่เล็กที่สุดของผ้า ไม่สามารถแยกย่อยในเชิงกลได้อีก

1.4.2. ผ้า (Fabric) เป็นวัสดุที่มีลักษณะเป็นแผ่นแบนสามารถผลิตจากสารละลาย เส้นใยเส้นด้าย หรือวัสดุพื้นฐานเหล่านี้ร่วมกัน

1.4.3. เส้นใยธรรมชาติ (natural fibers) เป็นพอลิเมอร์ชนิดหนึ่งที่มนุษย์รู้จักนำมาใช้ประโยชน์มาเป็นเวลานาน ซึ่งมีแหล่งกำเนิดมาจากธรรมชาติ สามารถแบ่งย่อยได้ 3 ประเภท คือ เส้นใยเซลลูโลสที่

พบในส่วนต่าง ๆ ของพืช เช่น เส้นใยฝ้าย (cotton) หนุ่น(kapok) ป่าน(flax) ลินิน (linen) เส้นใยจากสัตว์ (animal hairs) เช่น ขนแกะขนแพะ ไยไหม (silks) และเส้นใยที่ได้มาจากแร่ธาตุ เช่น เส้นใยหิน (asbestos)

1.4.4. เส้นใยสังเคราะห์ (synthetic fibers) เกิดจากการนำพอลิเมอร์สังเคราะห์มาปั่น โม่เลกุลของเส้นใยต้องมีขนาดยาว และมีการเรียงตัวของโม่เลกุลเป็นระเบียบตามแนวแกนเส้นใย เช่น ไนลอน (nylon) พอลิเอสเทอร์ (polyester) สเปนเด็กซ์ (spandex) อะคริลิก (acrylic) เป็นต้น

1.4.5. Fourier Transform Infrared (FTIR) เป็นเทคนิคที่ใช้ในการจำแนกประเภทของ สารอินทรีย์สารอนินทรีย์และพันธะเคมีในโม่เลกุล รวมถึงสามารถบอกถึงปริมาณองค์ประกอบที่มีอยู่ในโม่เลกุลของสารผสมตัวอย่างที่ทราบชนิด โดยทำการตรวจวัดการดูดกลืนรังสีอินฟราเรดของ ตัวอย่างที่มีความถี่ต่าง ๆ ซึ่งเป็นลักษณะเฉพาะตัวของแต่ละพันธะ

1.4.6. Spectroscopy เป็นวิธีวิเคราะห์ที่อาศัยการเกิดอันตรกิริยา (interaction) ระหว่าง รังสีหรือคลื่นแม่เหล็กไฟฟ้า (electromagnetic radiation) กับสารวิธีการสเปกโทรสโกปีมีขอบเขต กว้างหมายถึงย่านความถี่แสง (light) และพลังงานรูปอื่น โดยวิธีการสเปกโทรสโกปีจะเกี่ยวข้องกับ อันตรกิริยาอย่างใดอย่างหนึ่งของรังสีแม่เหล็กไฟฟ้าหรือแสงที่ช่วงพลังงานแตกต่างกัน ดังนั้นจึงมี วิธีวิเคราะห์หลายวิธี โดยถ่วงแบ่งตามการเกิดอันตรกิริยา ระหว่างรังสีแม่เหล็กไฟฟ้ากับสารจะแบ่งได้ 4 แบบคือ การดูดกลืน (absorption) การเปล่งออก (emission) การเรืองแสง (fluorescence) และการกระเจิงแสง (scattering) ในอันตรกิริยา

1.4.7. Near Infrared Spectroscopy (NIRS) เป็นการวิเคราะห์ตัวอย่างโดยใช้คุณสมบัติ การดูดกลืนแสงในช่วงความยาวคลื่นระหว่าง 800 – 2500 นาโนเมตร ทำให้โม่เลกุลเกิดการสั่น ที่ ความถี่สูงและดูดกลืนรังสีไว้ ซึ่งปริมาณการดูดกลืนแสงจะเป็นไปตามกฎของเบียร์ – แลมเบิร์ต (Beer – Lambert 'law)

1.4.8. สมการแลมเบิร์ตหรือกฎแลมเบิร์ต คือเมื่อรังสีแม่เหล็กไฟฟ้าที่มีความยาวคลื่นเดียว ผ่านตัวกลางเนื้อเดียว รังสีแม่เหล็กไฟฟ้าที่ถูกดูดกลืนจะลดลงแบบ exponential ตามความหนาของ ตัวกลางที่แสงผ่าน (path length, b) นั่นคือค่าการดูดกลืนแสง (absorbance) เป็นสัดส่วนโดยตรง กับความหนาของตัวกลางที่แสงผ่าน

1.4.9. สมการเบียร์หรือกฎของเบียร์ คือเมื่อรังสีแม่เหล็กไฟฟ้าที่มีความยาวคลื่นเดียวผ่าน ตัวกลางเนื้อเดียว รังสีแม่เหล็กไฟฟ้าที่ถูกดูดกลืนจะลดลงแบบ exponential ตามจำนวนของสารที่ ดูดกลืนแสง (absorbing species) นั่นคือค่าการดูดกลืนแสง (absorbance) เป็นสัดส่วนโดยตรงกับ ความเข้มข้นของสารที่ดูดกลืนแสง

1.5 สมมติฐานของการวิจัย

เซนเซอร์สเปกตรัม NeoSpectra-Micro (Si-Ware System, Egypt) ที่เลือกใช้ในงานวิจัยทำงานบนพื้นฐานเทคโนโลยีฟูเรียร์ทรานสฟอร์มอินฟราเรดสเปกโตรมิเตอร์ (FTIR) และมีค่า การดูดกลืนแสงในย่านใกล้อินฟราเรดในช่วงความยาวคลื่นในช่วง 1,350 ถึง 2,500 นาโนเมตร สามารถจำแนกสิ่งทอตามชนิดของเส้นใยออกเป็น 3 กลุ่มได้ สอดคล้องกับงานวิจัยของ ดูร์และคณะ (Du et al., 2022) ที่ใช้ช่วงความยาวคลื่น 900 ถึง 2,500 กู้ยหยางและคณะ (Guifang, Hai, & Xin, 2015) ที่ใช้ช่วงความยาวคลื่น 400 ถึง 1,800 และ โจว และคณะ (Zhou, Yu, Ding, & Wang, 2019) ที่ใช้ช่วงความยาวคลื่น 1,100 ถึง 2,300 ในการจำแนกสิ่งทอชนิดต่าง ๆ



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษาเอกสารและทฤษฎีที่เกี่ยวข้องกับการพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าเพื่อระบบเตารีดอัจฉริยะที่ควบคุมอุณหภูมิอัตโนมัติโดยในบทนี้จะกล่าวถึงข้อมูลพื้นฐานเกี่ยวกับสิ่งทอและเส้นใย เทคนิคสเปกโทรสโกปี วิธีการซัพพอร์ตเวกเตอร์แมชชีน การวัดประสิทธิภาพอัลกอริทึมการจำแนก และงานวิจัยที่เกี่ยวข้อง

2.1 ข้อมูลพื้นฐานเกี่ยวกับสิ่งทอและเส้นใย

2.1.1 เส้นใย หมายถึง หน่วยที่เล็กที่สุดของวัสดุสิ่งทอ คือ วัสดุหรือสารใด ๆ จากทั้งที่เกิดจากธรรมชาติ และมนุษย์สร้างขึ้น ที่มีอัตราส่วนระหว่างความยาวต่อเส้นผ่าศูนย์กลางเท่ากับหรือมากกว่า 100 เท่า สามารถขึ้นรูปเป็นผ้าได้จัดเป็นองค์ประกอบที่เล็กที่สุดของผ้าไม่สามารถแยกย่อยในเชิงกลได้อีก มักจะประกอบด้วยธาตุคาร์บอนและไฮโดรเจน มีออกซิเจนและไนโตรเจนเป็นองค์ประกอบบ้างเพียงเล็กน้อย มีน้ำหนักโมเลกุลสูงมาก และโมเลกุลมีลักษณะเป็นสายโซ่ยาว โดยแต่ละห่วงโซ่โมเลกุลจะมีโครงสร้างเหมือนกัน เรียกว่า โซ่โมเลกุล (Molecular Chain)

2.1.2 การแบ่งชนิดของเส้นใย (Fibers Classification) สามารถแบ่งได้ 2 ชนิด คือ เส้นใยธรรมชาติ (Natural Fiber) และเส้นใยประดิษฐ์ (Man-Made Fiber) โดยมีรายละเอียดดังนี้

2.1.2.1. เส้นใยธรรมชาติ ส่วนใหญ่เป็นชนิดเส้นใยเซลลูโลส (Cellulose Fibers) ที่ได้จากเมล็ด เช่น ฝ้าย (Cotton), หนุ่น (Kapok) หรือได้จากลำต้น เช่น ลินิน (flax), ป่านรามี่ (ramie) ซึ่งมีคุณสมบัติการดูดซับความชื้นได้ดี ทำให้เมื่อนำมาผลิตเป็นเสื้อผ้าจะสวมใส่สบาย แต่มีการคืนตัวต่ำทำให้เสื้อผ้ายับง่าย และมีความสามารถในทนต่ออุณหภูมิที่สูง ทำให้จำเป็นต้องรีดผ้าด้วยอุณหภูมิสูง

2.1.2.2. เส้นใยประดิษฐ์ (Man-Made Fiber) คือ เส้นใยที่สังเคราะห์โดยการนำโพลิเมอร์ธรรมชาติหรือสารเคมีโมเลกุลเล็ก ๆ ไปทำปฏิกิริยาจนได้โพลิเมอร์แล้วนำไปทำเป็นเส้นใย สามารถแบ่งเป็น 2 ประเภท คือ กลุ่ม Regenerate Fiber ได้แก่ เรยอน, อะซิเตท และ กลุ่มเส้นใยสังเคราะห์ (Synthetic Fiber) ได้แก่ ไนลอน (Nylon), โพลีเอสเตอร์ (Polyester), อะคริลิก (Acrylic), สเปนเดกซ์ (Spandex) ซึ่งเส้นใยจะมีคุณสมบัติแข็งแรงและทนทานต่อสารเคมี จุดหลอมเหลวต่ำทำให้ต้อง ระมัดระวังในการรีด

2.1.3. ผ้า (Fabric) หมายถึง วัสดุชนิดหนึ่งที่มีลักษณะเป็นแผ่นมีความกว้าง ความยาว และความหนาขนาดต่าง ๆ ถูกทอเป็นผืน และผ่านกระบวนการผลิตจากเส้นใยธรรมชาติ หรือสังเคราะห์ เกิดเป็นเส้นด้ายและผ่านกรรมวิธีผลิตจนได้เป็นผืน สามารถแบ่งเป็นได้ 3 ประเภท

2.1.3.1. ประเภทผ้าทอ (Weaving fabric) กรรมวิธีการนำเส้นด้ายมาขัดเข้าด้วยกัน มีเส้นใยด้าย คือ เส้นด้ายยืน (Warp yarn) และเส้นด้ายพุ่ง (Weft yarn)

2.1.3.2. ประเภทผ้าถัก (Knitted fabric) การนำเส้นด้ายต่อกันเป็นห่วง (Interlock loops) มีเส้นใยด้าย คือ เส้นด้ายแนวตั้ง (Wales) และเส้นด้ายแนวนอน (Course)

2.1.3.3. ประเภทผ้าไม่ถักไม่ทอ (non-Woven fabric) มีลักษณะโครงสร้างเป็นแผ่นผ้าที่เกิดจากการสานไปมาของเส้นใย (fibrous web) มีการยึดกันด้วยการที่เส้นใยพันกันไปมา (mechanical entanglement) หรือ ใช้ความร้อนเรซิน หรือ สารเคมีในการทำให้เกิดการยึดกันระหว่างเส้นใย

2.1.4. ความทนต่อความร้อน (Thermal Resistance) เส้นใยแต่ละชนิดทนต่อความร้อนแตกต่างกัน เส้นใยเซลลูโลส เช่น ขนสัตว์ เส้นไหม จะติดไฟง่ายและลุกไหม้รวดเร็วแต่เมื่อติดแล้วจะดับได้ด้วยตนเอง ในส่วนของเส้นใยสังเคราะห์เมื่อได้รับความร้อนสูงจะอ่อนตัวลง และเมื่อถึงจุดหลอมเหลวจะเหลวเป็นยางเหนียวคล้ายกับพลาสติก โดยมีอุณหภูมิที่เหมาะสมสำหรับผ้าแต่ละชนิดตามเส้นใยอ้างอิงจากมาตรฐานฉลากดูแลรักษาผลิตภัณฑ์สิ่งทอ ISO 3758-2012 (Textiles Care labelling code using symbols) และงานวิจัยของ (Cheriaa, Marzoug, & Sakli, 2016) ดังตาราง 1

ตาราง 1 อุณหภูมิที่เหมาะสมสำหรับการรีดผ้าแต่ละชนิดเส้นใย

ชนิดของเส้นใย	อุณหภูมิที่ใช้รีด °C	ชนิดของเส้นใย	อุณหภูมิที่ใช้รีด °C
ไนลอน	110±2	เรยอน	150±2
อะซิเตท	110±2	สเปนเดกซ์	150±2
ไหม	150±2	ฝ้าย	200±2
โพลีเอสเตอร์	150±2	ลินิน	200±2

2.2 หลักเทคนิคสเปกโทรสโกปี (Spectroscopy)

เป็นเทคนิคที่เกี่ยวข้องกับการวัดและวิเคราะห์ทางแสงหรือคลื่นแม่เหล็กไฟฟ้า ด้วยคุณสมบัติที่เป็นคลื่น จึงสามารถเกิดปรากฏการณ์เกี่ยวกับการสะท้อน (reflection) การหักเห (refraction) การเลี้ยวเบน (diffraction) หรือการกระเจิง (scattering) มีลักษณะเป็นแถบพลังงาน (Spectrum) โดยมีความยาวคลื่นตั้งแต่ในช่วงของคลื่นวิทยุ คลื่นไมโครเวฟ คลื่นอินฟราเรด คลื่นในช่วงที่ตามองเห็น (visible) ไปจนถึงคลื่นอัลตราไวโอเล็ต ดังตาราง 2 (วิชัย, 2555, หน้า 2-5)

ตาราง 2 ช่วงความยาวคลื่นของคลื่นรังสีต่าง ๆ

ชนิดรังสี	เลขคลื่น (Wavenumber: cm^{-1})	ความยาวคลื่น (Wavelength: λ ; nm)
แกมมา (Gamma)	$> 10^9$	< 0.01
เอกซ์ (X)	$10^7 - 10^9$	$1 - 0.01$
อัลตราไวโอเล็ต (UV)	$25,000 - 10^7$	$400 - 1$
วิสิเบิล (Visible)	$12,500 - 25,000$	$800 - 400$
อินฟราเรดย่านใกล้ (Near-Infrared)	$4,000 - 12,500$	$2,500 - 800^*$
อินฟราเรด (Mid & Far Infrared)	$10 - 4,000$	$10^5 - 2,500$
ไมโครเวฟ (Microwave)	~ 10	$10^8 - 10^5$
คลื่นวิทยุ (Radio Frequency)	< 0.1	$> 10^5$

สเปกตรัมการดูดกลืนแสง NIR เหมาะสำหรับการใช้วิเคราะห์เชิงคุณภาพและปริมาณ เนื่องจาก รังสีเปกโทรสโคปีอินฟราเรดย่านใกล้สามารถแบ่งได้ออกเป็น 2 ลักษณะ คือ การแบ่งตามระดับพลังงานและการแบ่งตามตำแหน่งแถบในสเปกตรัมอินฟราเรดย่านใกล้ของโมเลกุล ดังตาราง 3 (วิชัย, 2555, หน้า 2-5)(เซนเซอร์ที่เลือกใช้ทำงานในช่วง $1,300 - 2,500$)

ตาราง 3 ช่วงรังสีเปกโทรสโคปีอินฟราเรดย่านใกล้ตามระดับพลังงานและการใช้งาน

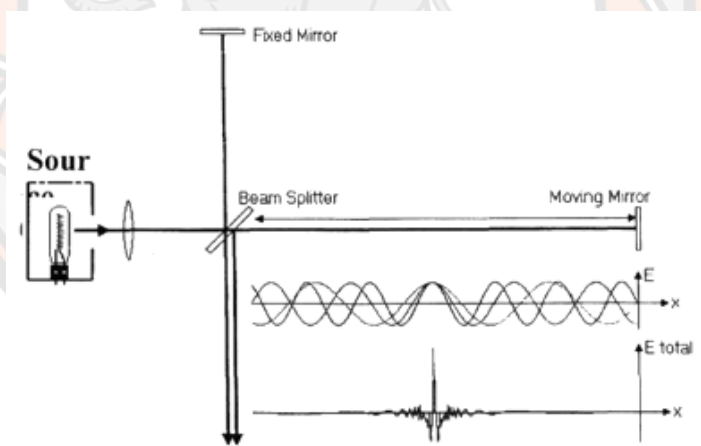
ช่วง	ความยาวคลื่น	พลังงานและการใช้งาน
คลื่นสั้น (Short wavelength NIR:SWNIR)	$800 - 1,100$ นาโนเมตร	$\sim 150 - 109$ kJ/mol เป็นช่วงพลังงานสูงสามารถทะลุทะลวงเข้าไปในเนื้อของตัวอย่างได้ดี โดยทั่วไปสามารถทะลุได้ถึง 1 เซนติเมตร จึงนิยมใช้ในการวิเคราะห์ตัวอย่างที่ต้องการได้ข้อมูลสเปกตรัมในเนื้อตัวอย่างสูง เช่น ผลไม้เปลือกหนา
คลื่นยาว (Long wavelength NIR:LWNIR)	$1,100 - 2,500$ นาโนเมตร	$\sim 109 - 48$ kJ/mol เป็นช่วงมีพลังงานต่ำ โดยทั่วไปลำแสงสามารถทะลุผ่านได้ไม่เกิน 5 มิลลิเมตร เหมาะกับตัวอย่างทั้งของแข็งและของเหลว และเป็นช่วงที่ให้ข้อมูลทางเคมีมากกว่าช่วงคลื่นสั้น เนื่องจากเป็นช่วงที่แถบโอเวอร์โทนอันดับที่หนึ่งและคอมบิเนชันปรากฏ

2.2.1. ฟลูอริเมตริกอินฟราเรดสเปกโทรสโคปี

เป็นเทคนิคหนึ่งด้านอินฟราเรดสเปกโทรสโคปีที่ใช้วิเคราะห์สารอินทรีย์ สารอนินทรีย์และพันธะเคมีโมเลกุล ทั้งในรูปแบบที่เป็นของแข็ง ของเหลวและแก๊ส รวมถึงสามารถบอกถึงปริมาณ

องค์ประกอบที่มีอยู่ในโมเลกุลของสาร โดยการอาศัยการกระตุ้นสารด้วยพลังงานแสงช่วงอินฟราเรด (Infrared light) ที่ความยาวคลื่นต่าง ๆ ซึ่งสารแต่ละชนิดจะเกิดการดูดกลืนแสงอินฟราเรดในช่วงความถี่ที่มีค่าเฉพาะแตกต่างกันแล้วทำให้เกิดการเคลื่อนไหวของพันธะ ปรากฏการณ์ที่เกิดขึ้นจะถูกบันทึกเป็นสเปกตรัม ซึ่งแสดงลักษณะเฉพาะและเมื่อนำไปเปรียบเทียบกับสเปกตรัมของสารมาตรฐาน (referent) ก็จะทราบชนิดของสารนั้น โดยเทคนิค FT-IR ถูกนำมาใช้แทนเครื่องอินฟราเรดสเปกโตรโฟโตมิเตอร์แบบธรรมดา เนื่องจากความรวดเร็วและความไวสูง นอกจากนี้ยังสามารถวิเคราะห์สารในช่วงที่แบบธรรมดาวิเคราะห์ได้ยากหรือเป็นไปได้

การทำงานของเครื่องสเปกโตรมิเตอร์อินฟราเรดย่านไกล อาศัยการดูดกลืนพลังงานแสงในแต่ละช่วงความยาวคลื่นของสารแต่ละชนิดไม่เท่ากัน ดังนั้นเครื่องมือส่วนใหญ่จำเป็นต้องมีความสามารถที่เรียกว่า โมโนโครเมเตอร์ (monochromator) ดังภาพ 1 คือ การแยกลำแสงออกเป็น ที่ละความยาวคลื่นเพื่อส่งไปยังตัวอย่าง และวัดค่าความเข้มของแสงที่สะท้อนออกมา (Reflected Type) หรือ วัดความเข้มของแสงที่ทะลุผ่าน (Transmittance Type) เปรียบเทียบกับความเข้มที่ส่องเข้า ทำให้สามารถนำความเข้มแสงที่ได้ในแต่ละความยาวคลื่นมาเขียนกราฟที่แนวนอนเป็นความยาวคลื่น (wavelength: nm) และแนวตั้งแสดงค่าการดูดกลืนแสง (absorbance) ของตัวอย่างนั้น ๆ



ภาพ 1 หลักการทำงานของอินเตอร์เฟอโรมิเตอร์แบบไมเคิลสัน

ที่มา: เทคโนโลยีอินฟราเรดย่านไกลและการประยุกต์ใช้ในอุตสาหกรรม, 2012

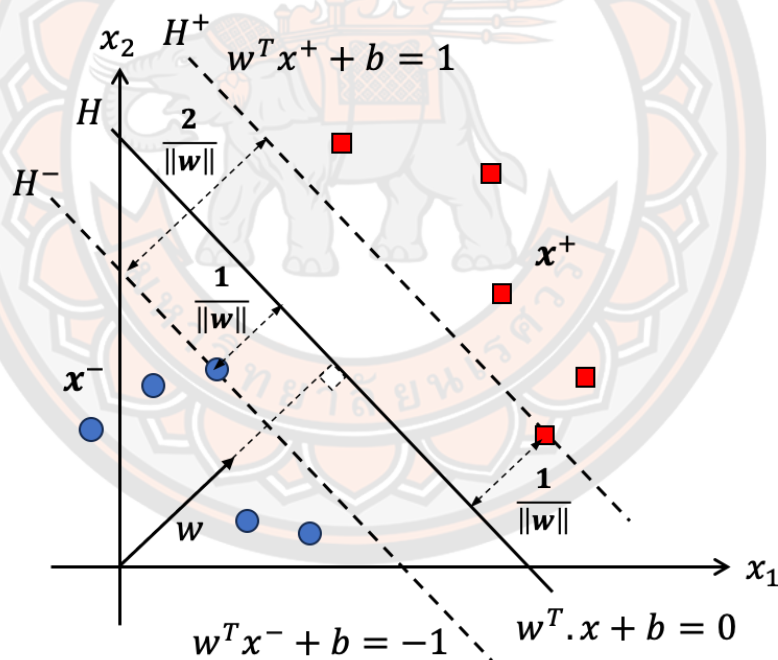
หลักการสร้างเครื่องสเปกโตรมิเตอร์อินฟราเรดย่านไกล มีด้วยกันหลายวิธี อาทิเช่น การใช้เทคนิคแปลงเฟียร์ (Fourier Transforms Technique) หลักการเกรตติ้งเคลื่อนที่ (Moving Gratings) หลักการฟิลเตอร์เชิงแสง (Optical Filter) และหลักการแถวลำดับไดโอด (Diode Arrays) ซึ่งเซนเซอร์ที่ใช้ในงานวิจัยนี้ ทำงานบนพื้นฐานเทคโนโลยี FT-IR ทำให้สามารถวิเคราะห์ข้อมูลทั้งใน

เชิงปริมาณและเชิงคุณภาพ นอกจากนี้ เซนเซอร์ยังออกแบบโดยใช้เทคโนโลยีเมมส์ (MEMS) ทำให้สามารถสร้างอินเตอร์เฟอโรมิเตอร์แบบไม่เคลือบสั่น รวมไปถึงได้ในที่เดียวและใช้วิธีการวัดการสะท้อนแบบแพร่ (diffuse reflectance) ในการวัดค่าดูดกลืนแสง

2.3 วิธีการซัพพอร์ตเวกเตอร์แมชชีน

2.3.1. วิธีการซัพพอร์ตเวกเตอร์แมชชีน

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine, SVM) จัดเป็นการเรียนรู้ประเภทการเรียนรู้โดยมีผู้สอน (Supervised Learning) ที่ยืดหยุ่นและทำงานได้ดี โดยเฉพาะอย่างยิ่งเมื่อข้อมูลมีความซับซ้อนหลายพีเจอร์ (Feature) แต่จำนวนตัวอย่างไม่มาก สามารถใช้ทั้งการจำแนกประเภทข้อมูล (Classification) และการทำนาย (Regression) ด้วยการหาระยะขอบที่มากที่สุด (Maximum Margin) ของระนาบตัดสินใจ (Decision Hyperplane) ที่แบ่งแยกข้อมูลที่ใช้ฝึกฝนออกจากกัน



ภาพ 2 ระนาบการตัดสินใจ (Hyperplane) ของ SVM

จากภาพ 2 ทำการแสดงความสัมพันธ์ของคู่ลำดับ (x_1, x_2) ใดๆ ที่สามารถจำแนกได้ 2 ลักษณะคือ คู่ลำดับในคลาส x^+ ซึ่งมีลักษณะเป็นสีเหลี่ยม และคู่ลำดับในคลาส x^- ที่มีลักษณะเป็นวงกลม โดยการแบ่งแยกข้อมูลให้ออกเป็น 2 กลุ่มโดยใช้เส้นแบ่งแยก (Hyperplane) ซึ่งได้มาจากการพิจารณาขอบกั้นของเส้นแบ่งข้อมูล (Margin) ระหว่างเส้นแบ่งแยก H^+ และ H^- ที่เป็นลักษณะการจำแนกอย่างเชิงเส้น (Linearly Separable) และแบ่งข้อมูลออกเป็น 2 คลาส ได้แก่

Positive Class และ Negative Class โดยที่ x_i เป็นค่าข้อมูลของคู่ลำดับในชุดความสัมพันธ์ระหว่างเวกเตอร์ที่ใช้สำหรับฝึกฝนจำนวน n ข้อมูล คือ $\{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_n, y_n)\}$ และ y_i เป็นค่าสำหรับกำหนดการแบ่งกลุ่มข้อมูล โดยกำหนดให้ $y_i = 1$ สำหรับ x_i เป็นข้อมูลประเภทบวก (Positive Class) และ $y_i = -1$ สำหรับ x_i เป็นข้อมูลประเภทลบ (Negative Class) ทำให้สามารถเขียนสมการเส้นแบ่งแยก (Equation of an Hyperplane) ได้ดังนี้ (เทอดศักดิ์และคณะ, 2018)

$$w^T x + b = 0 \quad (2-1)$$

โดยที่ w^T คือ เวกเตอร์ตั้งฉากของค่าความชัน m ของระนาบตัดสินใจ
 b คือ ค่าคงที่ที่ได้จากค่าแกน y ของแต่ละข้อมูล x

เมื่อนำสมการเส้นแบ่งแยกไปพิจารณาภายใต้เงื่อนไขที่สามารถจำแนกข้อมูลได้เป็น 2 คลาส คือ คลาสที่เป็นประเภทบวก (Positive Class) นั่นคือ $w^T x^+ + b = 1$ หรือเส้นแบ่งแยก H^+ และคลาสที่เป็นประเภทลบ (Negative Class) นั่นคือ $w^T x^- + b = -1$ หรือเส้นแบ่งแยก H^- ทำให้สามารถจำแนกเป็นเชิงเส้นได้ Hyperplane $f(x_i)$ ภายใต้เงื่อนไขดังนี้

$$w^T x_i + b \geq 1, y_i = 1$$

$$w^T x_i + b \leq -1, y_i = -1$$

ในทางอุดมคติเส้นแบ่งที่ดีที่สุดที่สามารถแบ่งข้อมูลทั้งสองประเภทได้อย่างสมบูรณ์ หมายถึง ระยะห่างจาก Hyperplane ไปยังข้อมูลประเภทบวก (+) จะต้องมียุทธศาสตร์ที่ใกล้ที่สุด เท่ากับ ระยะห่างจาก Hyperplane ไปยังข้อมูลประเภทลบ (-) ที่ใกล้ที่สุดเช่นเดียวกัน กล่าวคือ ควรจะมีค่ามากที่สุดเท่าที่จะทำได้ของระยะห่าง (Maximal Margin) ทั้งนี้หากนำ y_i ของคลาสที่เป็นลบ คือ (-1) คูณเข้าทั้งสองข้างของสมการ H^- และนำค่านำ y_i ของคลาสที่เป็นบวก คือ (+1) คูณเข้าทั้งสองข้างของสมการ H^+ ทำให้สามารถเขียนสมการใหม่ได้ดังนี้

$$y_i(w^T x_i + b) \geq 1, \text{ สำหรับ } i = 1, 2, 3, \dots, n \quad (2-2)$$

ดังนั้นภายใต้ฟังก์ชันการตัดสินใจ คือ การหาเส้นแบ่งแยกที่เหมาะสมที่สุด ด้วยการหาค่าสูงสุดของระยะห่าง (Margin) ภายใต้เงื่อนไขของขอบเขตสามารถแสดงได้จากปัญหาการหาค่าสูงสุดได้ดังสมการ

$$\text{Maximize } \frac{2}{\|w\|}, \text{ subject to: } y_i(w^T x_i + b) \geq 1 \quad (2-3)$$

จากสมการที่ 2-5 สามารถพิจารณาได้อีกรูปแบบหนึ่ง คือ การหา Minimize ของ ระยะทาง w ภายใต้เงื่อนไขข้างต้นดังสมการ

$$\text{Minimize } \frac{1}{2} \|w\|^2, \text{ subject to: } y_i(w^T x_i + b) \geq 1 \quad (2-4)$$

2.3.2 ซัพพอร์ตเวกเตอร์แมชชีนแบบหลายคลาส (Multi-Class SVM)

โดยพื้นฐานซัพพอร์ตเวกเตอร์แมชชีนจะใช้ในการ จำแนกกลุ่มข้อมูลแบบสองกลุ่ม (Binary Classification) ด้วยการสร้างระนาบเพื่อตัดสินใจ สำหรับการประยุกต์ใช้ในคัดแยกกลุ่มข้อมูลที่มากกว่าสองกลุ่ม จะทำได้โดยการเปรียบเทียบแยกทีละคู่ หลังจากนั้นจะหาข้อสรุปว่าข้อมูล อยู่กลุ่มใด โดยมีวิธีที่นิยมอยู่ 2 วิธี คือ

2.3.2.1 การคัดแยกทีละหนึ่งเปรียบเทียบกับส่วนที่เหลือทั้งหมด (One-Against-All) เป็นการเลือกคลาสใดหนึ่งคลาสเพื่อเปรียบเทียบกับคลาสอื่น ๆ ที่เหลือจนครบทุกคลาส ดังนั้นหาก จำนวนข้อมูลมี K คลาส วิธีการนี้จะจำแนกแบบสองกลุ่มจำนวน K ครั้ง การสร้างฟังก์ชันตัดสินใจ สำหรับจำแนกในแต่ละครั้งคลาสที่ถูกเลือกจะเป็นชุดข้อมูลบวก ($y_i = 1$) และคลาสที่เหลือจะเป็น ชุดข้อมูลลบ ($y_i = -1$) การตัดสินใจว่าผลลัพธ์การจำแนกเป็นคลาสใดจะใช้วิธีการ Winner-Takes-All คือ คลาสที่มีจำนวนการระบุผลลัพธ์การจำแนกมากที่สุด (พรพล, 2552)

2.3.2.2 ซัพพอร์ตเวกเตอร์แมชชีนแบบหนึ่งต่อหนึ่ง (One-against-One) เป็นการเปรียบเทียบกลุ่มข้อมูลจำนวน K คลาส โดยทำการเปรียบเทียบจำแนกกลุ่มข้อมูล แบบสองกลุ่ม (Binary Classification) ทีละคู่แบบไม่ซ้ำกันจนครบทุกคลาส ทำให้ได้ฟังก์ชันการตัดสินใจในการจำแนกจำนวน $K(K-1)/2$ ครั้ง ยกตัวอย่างเช่น หากข้อมูลมี 3 คลาสจะทำให้มีจำนวนฟังก์ชันการตัดสินใจจำนวน $3(3-1)/2 = 3$ ครั้ง ดังตาราง 4 สำหรับการเปรียบเทียบแต่ละคู่คลาส เช่น การเปรียบเทียบกลุ่มที่ 1 กับกลุ่มที่ 2 หากฟังก์ชันการตัดสินใจ $f_1(x)$ ได้ค่าเป็นบวกหมายถึงจำแนกได้ เป็นกลุ่มที่ 1 แต่หากมีค่าเป็นลบ หมายถึง จำแนกเป็นกลุ่มที่ 2 และในการตัดสินใจว่าผลลัพธ์การ จำแนกเป็นกลุ่มใด จะใช้วิธีการ Max-Wins คือ กลุ่มที่ได้ผลลัพธ์การจำแนกมากกว่าจะถูกเลือกเป็น ผลลัพธ์ (เทอดศักดิ์และคณะ, 2018, หน้า 55) โดยในงานวิจัยนี้ได้นำเสนอวิธีการจำแนก 3 คลาสที่ เปรียบเทียบกับวิธีการนี้แต่ใช้จำนวนฟังก์ชันการตัดสินใจแค่ 2 ฟังก์ชัน


ตาราง 4 ซัพพอร์ตเวกเตอร์แมชชีนแบบหนึ่งต่อหนึ่ง

$y_i = 1$	$y_i = -1$	ฟังก์ชันการตัดสินใจ
กลุ่มที่ 1	กลุ่มที่ 2	$f1(x) = w_1^T x + b_1$
กลุ่มที่ 1	กลุ่มที่ 3	$f2(x) = w_2^T x + b_2$
กลุ่มที่ 2	กลุ่มที่ 3	$f3(x) = w_3^T x + b_3$

2.4 การวัดประสิทธิภาพของโมเดล

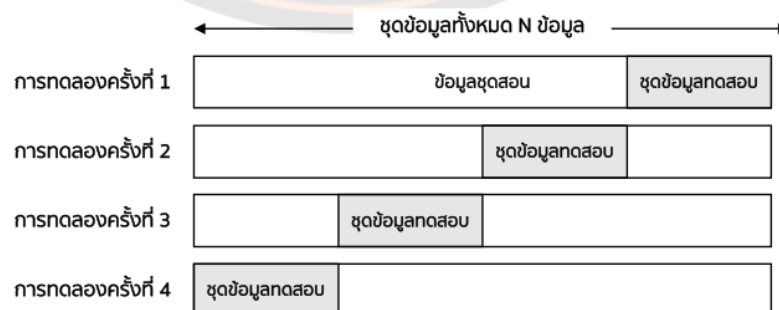
2.4.1 การตรวจสอบความถูกต้องของการเรียนรู้ (Cross Validation) เพื่อใช้ดูค่าความแม่นยำหรือความผิดพลาดที่ได้จากการทำ Cross-Validation ซึ่งมีรูปแบบการทดลองเพื่อประเมินหลายวิธีดังนี้

2.4.1.1 การเลือกสุ่มข้อมูลแบบร้อยละ (Percentage) ทำได้โดยเลือกสุ่มข้อมูลชุดสอนตามร้อยละที่กำหนดและใช้ข้อมูลที่เหลือเป็นชุดทดสอบ ข้อดีของวิธีการนี้คือเป็นวิธีการสุ่มข้อมูลที่ง่าย แต่มีข้อเสียคือข้อมูลทุกตัวไม่ได้ถูกนำมาเป็นข้อมูลชุดข้อมูลชุดสอนและชุดข้อมูลทดสอบ ดังแสดงในภาพ 3



ภาพ 3 การเลือกสุ่มข้อมูลแบบร้อยละ

2.4.1.2 การเลือกสุ่มแบบความเที่ยงตรง K กลุ่ม (K-Fold Cross Validation) ทำการเลือกสุ่มข้อมูลออกเป็น K ชุดเท่ากัน โดยต้องสุ่มข้อมูลทุกตัวจะถูกนำมาเป็นชุดข้อมูลชุดสอนและชุดข้อมูลทดสอบ ดังแสดงในภาพ 4



ภาพ 4 การเลือกสุ่มแบบความเที่ยงตรง K กลุ่ม เมื่อ K=4

2.4.2 ตาราง Confusion Matrix

ตารางสร้างผลการทำนาย (Confusion Matrix) คือ การประเมินผลลัพธ์การทำนายของแบบจำลอง (Predict) เปรียบเทียบกับผลลัพธ์จริงหรือผลเฉลยที่ทราบค่าจริงอยู่แล้ว (Actual) การวัดประสิทธิภาพของแบบจำลองการทำนายในปัญหาแบบการจำแนกประเภทประกอบไปด้วย ตารางสร้างผลการทำนาย (Confusion Matrix) Positive Class เป็นคลาสของข้อมูลที่กำลังพิจารณาและ Negative Class เป็นคลาสของ เพื่อวัดที่คำตอบที่อัลกอริทึมทำนายกับคำตอบจริงของข้อมูลที่ใช้ในการทดสอบ ซึ่งถ้าเป็นการจำแนกแบบมีเพียง 2 คำตอบ (Binary Classification) จะใช้ตาราง Confusion Matrix ดังตาราง 5 โดยกำหนดให้

True Positive (TP) หมายถึง สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้นจริง ในกรณีทำนายว่าจริง และสิ่งที่เกิดขึ้นก็ คือ จริง

True Negative (TN) หมายถึง สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้น ในกรณีทำนายว่าไม่จริง และสิ่งที่เกิดขึ้น คือ ไม่จริง

False Positive (FP) หมายถึง สิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้น คือทำนายว่า จริง แต่สิ่งที่เกิดขึ้น คือ ไม่จริง

False Negative (FN) หมายถึง สิ่งที่ทำนายไม่ตรงกับที่ที่เกิดขึ้นจริง คือทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้น คือ จริง

ตาราง 5 Confusion Matrix แบบ Binary Classification

		Actual	
		Positive	Negative
Predicted	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

แต่ในงานวิจัยนี้มีคำตอบที่ต้องการทำนายจำนวน 3 คลาส จึงต้องออกแบบใช้ Confusion Matrix แบบ Multi-class ดังตาราง 6 และสามารถอธิบายผลลัพธ์การทำนายในรูปแบบของค่า TP, FN, FP และ TN สำหรับแต่ละคลาสดังตาราง 7 (Yammen & Limsripraphan, 2022)

ตาราง 6 Confusion Matrix แบบ Multi-class Classification

		Actual Class		
Predicted Class	Class	Natural	Synthetic	Blended
	Natural	C11	C12	C13
	Synthetic	C21	C22	C23
	Blended	C31	C32	C33

ตาราง 7 แสดงตาราง Confusion Matrix แบบ Multi-class Classification

	Natural	Synthetic	Blended
TP	C11	C22	C33
FN	C21 + C31	C12 + C32	C13 + C23
FP	C12 + C13	C21 + C23	C31 + C32
TN	C22+C23+C32+C33	C11+C13+C31+C33	C11+C12+C21+C22

และใช้ค่าจาก Confusion Matrix ที่ได้มาคำนวณประเมินประสิทธิภาพของ
การทำนายอัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใยจำแนกตามคลาสดังนี้

ค่าความถูกต้อง (Accuracy)

คือ จำนวนข้อมูลที่ทำนายได้ถูกต้องของทุกคลาสดตรงกับข้อมูลจริง ดังสมการ

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

ค่าความแม่นยำ (Precision)

คือ สัดส่วนการทำนายที่ถูกต้องว่าจริงและที่เกิดขึ้นจริงจากทำนายทั้งหมด

ดังสมการ

$$Precision = \frac{TP}{TP + FP}$$

ค่าความระลึก (Recall)

คือ สัดส่วนการทำนายที่ถูกต้องว่าจริงและที่เกิดขึ้นจริงจากข้อมูลจริงทั้งหมด

ดังสมการ

$$Recall = \frac{TP}{TP + FN}$$

2.5 งานวิจัยที่เกี่ยวข้อง

2.5.1 งานวิจัยที่ใช้เทคนิค NIR Spectroscopy ในการจำแนกสิ่งทอ

เทคนิคสเปกโทรสโกปีอินฟราเรดย่านใกล้ (NIR) ถูกนำมาใช้ในการจำแนกสิ่งทอตามชนิดของเส้นใย หรือ การระบุคุณภาพ/ปริมาณของเส้นใย เนื่องจากเป็นเทคนิคที่ให้ผลที่วิเคราะห์ขององค์ประกอบทางเคมีที่แม่นยำโดยไม่ทำลายตัวอย่าง และรวดเร็ว จึงเป็นประเด็นที่ได้รับความสนใจจากกลุ่มนักวิจัยและมีการใช้เมธอดในการวิเคราะห์หรือจำแนกที่หลากหลาย รวมถึงการระบุคุณภาพ/ปริมาณของเส้นใยหลายดังนี้

ก๊วยหยาง และคณะ (Guifang et al., 2015) ได้ทำวิจัยการจำแนกประเภทของผ้ากลุ่มเส้นใยธรรมชาติจำนวน 4 ชนิด ได้แก่ cotton, flax, silk และ cashmere ด้วยข้อมูลสเปกตรัมย่าน VIS/NIR จำนวน 180 ตัวอย่าง โดยใช้เทคนิคการวิเคราะห์องค์ประกอบหลัก (PCA) ในการลดจำนวนและดึงคุณลักษณะของตัวแปรที่มีความสำคัญให้เหลือ 6 PCs เพื่อเปรียบเทียบผลลัพธ์แบบจำลองในการจำแนกด้วย LS-SVM และ PCA-LS-SVM ผลการวิจัยพบว่า PCA-LS-SVM ให้ผลลัพธ์การจำแนกที่ดี จึงแสดงให้เห็นว่าสเปกตรัมอินฟราเรดย่านใกล้สามารถใช้อำนาจจำแนกผ้าทั้งในมุมมองของคุณลักษณะเฉพาะหรือเชิงคุณภาพได้

ดาร์ซิลวา บรารูม และคณะ (da Silva BarrosM, Ohata, da Silva, Almeida, & Rebouças Filho, 2020) นำเสนอวิธีการจำแนกสิ่งทอผ้าที่ใช้สำหรับตัดเสื้อผ้าที่ขายตามตลาดเสื้อผ้าเพื่อแก้ปัญหาให้ผู้บริโภคสามารถตัดสินคุณภาพสิ่งทอของเสื้อผ้าสวมใส่ จำนวน 13 ชนิด โดยการใช้เทคนิคการประมวลผลภาพร่วมกับโครงข่ายประสาทแบบคอนโวลูชัน (CNN) ในการสกัดคุณลักษณะข้อมูลภาพถ่ายผ้าจากมือถือ แล้วใช้เป็นข้อมูลนำเข้าเพื่อสร้างแบบจำลองการจำแนก เปรียบเทียบกัน 5 วิธี คือ Naive Bayes, Multilayer Perceptron, k-NN, Random Forest และ SVM ผลการวิจัยพบว่า การสกัดคุณลักษณะด้วยวิธี DenseNet201 ร่วมกับแบบจำลอง SVM มีค่าความถูกต้อง (Accuracy) และ F1-Score ดีที่สุดที่ 94.350% และ 94.296% ตามลำดับ

2.5.2 งานวิจัยที่ใช้เซนเซอร์ NeoSpectra Micro ในงานด้านต่าง ๆ

แมคเวย์ และคณะ (McVey, Elliott, et al., 2021; McVey, McGrath, Haughey, & Elliott, 2021) ใช้อุปกรณ์ NIR Neo-Spectra Micro ในการตัดสินความเป็นออริกาโนแท้และสิ่งแปลกปลอมที่เจือปน โดยใช้เมธอดที่แตกต่างกันในซอฟต์แวร์ SIMCA ซอฟต์แวร์ งานวิจัยนี้แสดงให้เห็นว่าอุปกรณ์ Neo-Spectra Micro สามารถประยุกต์ใช้ได้ในพื้นที่ต่าง ๆ ในห่วงโซ่อุปทานอาหาร ด้วยการทำงานที่รวดเร็วและคุ้มค่า สามารถเคลื่อนย้ายได้

จู่ และคณะ (Zhu et al., 2022) ใช้เซนเซอร์ Neo-Spectra Micro ที่เป็นสเปกโตรมิเตอร์อินฟราเรดย่านใกล้แบบพกพาในย่าน FT-NIR สำหรับวัดคุณสมบัติคุณภาพ (เบต้า-กลูแคน แป้ง

โปรตีน และไขมัน) ของข้าวโอ๊ตเพื่อสนับสนุนการคัดเลือกพันธุ์ โดยใช้โมเดล PLSR ผลการวิจัย พบว่า เซนเซอร์ NIR ให้วิธีการที่รวดเร็ว (15 วินาที) ในการคัดกรองลักษณะเฉพาะในภาคนามด้วยความน่าเชื่อถือและความไวเทียบเท่ากับระบบตั้งโต๊ะ

ริว และคณะ (Giussani, 2021) ได้ศึกษาการใช้สเปกโตรมิเตอร์อินฟราเรดย่านใกล้แบบพกพาสำหรับการวิเคราะห์ผลิตภัณฑ์ในอุตสาหกรรมนม โดยปัจจุบันมีอยู่หลายตัว อาทิ SciO (Consumer Physics), MicroPhazir (Thermo Fisher), MicroNIR (Viavi Solutions), NIRscan Nano Evaluation Module (Texas Instruments) และ Neo-Spectra Micro (Si-Ware Systems) ผลการศึกษา พบว่า เครื่องมือ NIR แบบพกพาให้ช่องสเปกตรัมที่เล็กมากเมื่อเทียบกับเครื่องมือแบบตั้งโต๊ะ ทำให้การวิเคราะห์ข้อมูลขั้นสุดท้ายไม่เร็วและง่ายอย่างที่ควรจะเป็น แต่เครื่องมือ NIR แบบพกพาจะช่วยให้การวิเคราะห์นอกสถานที่หรือแบบออนไลน์ทำได้ง่ายและเกิดขึ้นได้



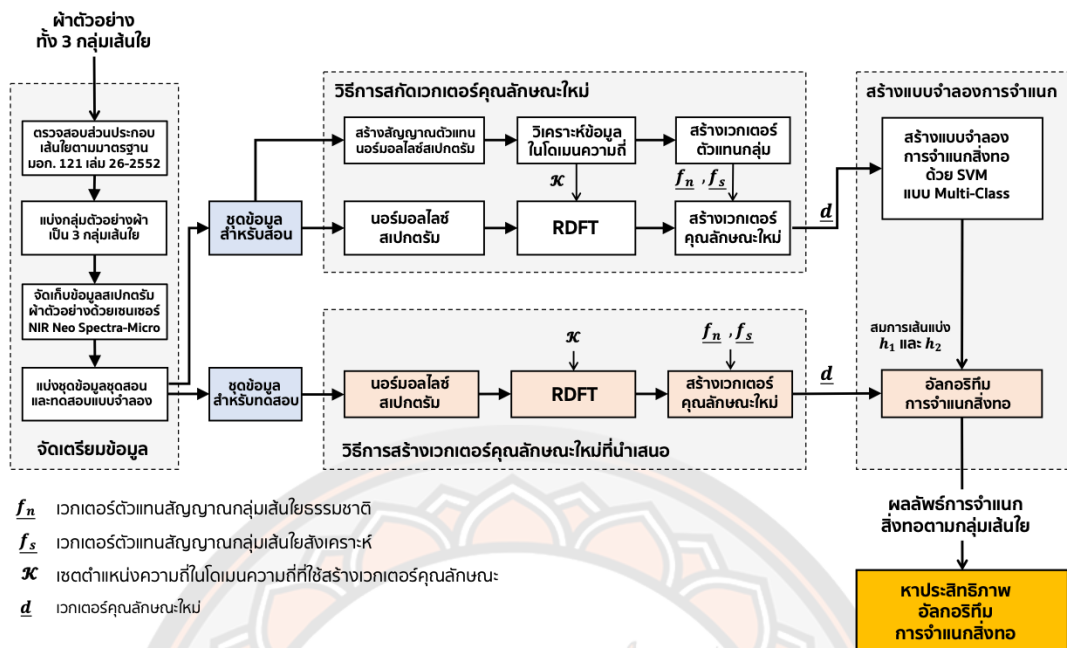
บทที่ 3

วิธีดำเนินการวิจัย

งานวิจัยนี้มุ่งเน้นเกี่ยวกับการพัฒนาอัลกอริทึมจำแนกสิ่งทอตามชนิดของเส้นใยผ้า บนพื้นฐานข้อมูลจากเซนเซอร์สเปกตรัมในย่านใกล้อินฟราเรดที่สามารถทำงานบนระบบสมองกลฝังตัว ซึ่งไม่มีทรัพยากรในการประมวลผลที่สูงมาก และได้แบ่งการดำเนินการวิจัยออกเป็น 3 ส่วน คือ ส่วนซอฟต์แวร์ที่จะพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าได้ ส่วนฮาร์ดแวร์ที่พัฒนาต้นแบบเตารีดไฟฟ้าให้ความร้อนแบบเหนียวนำที่ควบคุมอุณหภูมิตามที่กำหนดโดยอัตโนมัติ และส่วนการวัดประสิทธิภาพอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า


3.1 ส่วนดำเนินการด้านซอฟต์แวร์ที่พัฒนาอัลกอริทึม

ในการจำแนกสิ่งทอ ตามชนิดผ้าของเส้นใยเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ กลุ่มผ้าเส้นใยผสม บนพื้นฐานข้อมูลจากเซนเซอร์สเปกตรัมในย่านใกล้อินฟราเรด โดยใช้ กลุ่มตัวอย่างผ้าที่ผ่านการตรวจสอบส่วนประกอบของเส้นใยตามมาตรฐาน มอก.121 เล่ม 26-2552 (สำนักงานมาตรฐานผลิตภัณฑ์อุตสาหกรรม, 2552) เพื่อนำไปวิเคราะห์และสร้างเวกเตอร์คุณลักษณะใหม่ ในโดเมนความถี่ก่อนนำไปใช้เป็นอินพุตในการสร้างแบบจำลองการจำแนกด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีนและอัลกอริทึมที่พัฒนา ดังแสดงในภาพ 5



ภาพ 5 ไดอะแกรมการพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าของเส้นใย

ผลลัพธ์การจำแนกสิ่งทอตามกลุ่มเส้นใยจะถูกใช้เป็นเงื่อนไขการระบุอุณหภูมิที่เหมาะสมสำหรับการรีดผ้าที่ผลิตจากเส้นใยชนิดต่าง ๆ ตามที่ระบุในบทที่ 2 ซึ่งสามารถแบ่งช่วงความร้อนของการรีดผ้าให้สอดคล้องกับป้ายการดูแลรักษาผลิตภัณฑ์ผ้าตามระบบ The European Care Labelling หรือ The American Care Labelling โดยแบ่งอุณหภูมิสำหรับการรีดออกเป็น 3 ช่วงตามสัญลักษณ์ คือ 1) รีดด้วยอุณหภูมิต่ำ ไม่เกิน 110 องศาเซลเซียส ซึ่งเหมาะสำหรับผ้าใยสังเคราะห์ 2) รีดด้วยอุณหภูมิมกกลาง ไม่เกิน 150 องศาเซลเซียส ซึ่งเหมาะสำหรับผ้าใยธรรมชาติที่มีผ้าใยสังเคราะห์ผสมบางส่วนและ 3) รีดด้วยอุณหภูมิสูงไม่เกิน 200 องศาเซลเซียสซึ่งเหมาะกับการรีดผ้าใยธรรมชาติทั่วไป (Coats, 2014) ดังภาพ 6



ภาพ 6 สัญลักษณ์อุณหภูมิการรีดผ้าของป้ายการดูแลรักษาผลิตภัณฑ์ผ้า

3.1.1. ประชากรและกลุ่มตัวอย่าง

ตัวอย่างผ้าที่ใช้ทดสอบในงานวิจัยเป็นผ้าผืนที่นิยมใช้ในการตัดเย็บเสื้อผ้าจากโรงงาน และแหล่งจำหน่ายในประเทศไทย โดยรวบรวมตามชนิดของเส้นใยจำนวน 3 กลุ่ม คือ กลุ่มตัวอย่างผ้าที่ทำจากเส้นใยธรรมชาติ กลุ่มตัวอย่างผ้าที่ทำจากเส้นใยสังเคราะห์ และกลุ่มตัวอย่างผ้าที่ทำจากเส้นใยธรรมชาติผสมกับเส้นใยสังเคราะห์ในสัดส่วนที่แตกต่างกัน และผ้า แต่ละชนิดจะมีสีแตกต่างกัน จำนวน 3 สี รวมตัวอย่างผ้าทั้งหมดที่ใช้ในงานวิจัย 96 ตัวอย่างผ้า และทุกตัวอย่างผ้าได้ส่งตรวจสอบความถูกต้องของส่วนประกอบเส้นใยจากศูนย์วิเคราะห์ทดสอบสิ่งทอ หน่วยงานสถาบันพัฒนาอุตสาหกรรมสิ่งทอ (Thailand Textile Institute) ซึ่งดำเนินงานภายใต้อุตสาหกรรมพัฒนามูลนิธิ และเป็นหน่วยงานเครือข่ายของกระทรวงอุตสาหกรรม

3.1.2. เครื่องมือที่ใช้ในการวิจัย

3.1.2.1. เซนเซอร์ NeoSpectra-Micro รุ่น SWS62231 ที่ทำงานบนพื้นฐานเทคโนโลยี ฟูเรียร์ทรานฟอร์มอินฟราเรดสเปกโตรมิเตอร์ และมีค่าการดูดกลืนแสงที่อยู่ในย่านใกล้อินฟราเรด ในช่วงความยาวคลื่นในช่วง 1350 ถึง 2500 นาโนเมตร ซึ่งมีงานวิจัยในหลากหลายสาขาวิชาที่แสดงให้เห็นว่าเซนเซอร์ Neo-Spectra Micro เป็นเครื่องมือ NIR แบบพกพาที่สามารถใช้ในการวิเคราะห์นอกสถานที่หรือแบบออนไลน์ ที่ทำได้ง่ายและเหมาะสมกับลักษณะภาคสนาม มีความน่าเชื่อถือและความไวเทียบเท่ากับเครื่องสเปกโตรมิเตอร์ระดับห้องปฏิบัติการ อาทิเช่น ในด้านอาหาร (Chadalavada et al., 2022; Giussani, Escalante-Quiceno, Boqué, & Riu, 2021; McVey, Elliott, et al., 2021; McVey, McGrath, et al., 2021) หรือในด้านสุขภาพของฮาปิบูลเลาะห์ และคณะ (Habibullah, ninda, Bahar, Dinh, & Wahid, 2019) หรือในด้านเกษตรกรรมของดูร์ และคณะ (Du et al., 2022) รวมถึงด้านการจำแนกสิ่งทอ (Riu, Gorla, & Giussani, 2021; Yammen & Limsripraphan, 2022; Zhu et al., 2022)

3.1.2.2. บอร์ดสมองกลฝังตัวที่ใช้หน่วยประมวลผลตระกูล ARM11 ที่สามารถติดตั้งระบบปฏิบัติการแบบ Opensource และรองรับการพัฒนาโปรแกรมด้วยภาษา C/C++ และ ภาษา Python รวมถึงมีช่องเชื่อมต่อการสื่อสารอนุกรมแบบ SPI (Serial Peripheral Interface) เพื่อเชื่อมต่อกับเซนเซอร์ NeoSpectra-Micro

3.1.2.3. ซอฟต์แวร์ MATLAB สำหรับใช้ในการวิเคราะห์สร้างแบบจำลองทางคณิตศาสตร์ในการจำแนกประเภทสิ่งทอจากเส้นใย


3.1.3. การเก็บรวบรวมข้อมูล

3.1.3.1. เตรียมตัวอย่างผ้าแต่ละชนิดให้มีขนาด 30 x 50 เซนติเมตรเพื่อให้เหมาะสมต่อการทดสอบ และทำการแบ่งออกเป็น 2 ชุด พร้อมติดหมายเลขอ้างอิง คือ ชุดสำหรับการทดสอบ

ในงานวิจัยรวมจำนวน 96 ผืน และชุดสำหรับส่งทดสอบส่วนประกอบเส้นใย โดยผ้า แต่ละชนิดจะทำเลือกส่งเพียงหนึ่งสีทำให้รวมตัวอย่างผ้าที่ส่งทดสอบรวมจำนวน 32 ผืน

3.1.3.2. ทำการจัดส่งตัวอย่างผ้าทั้งหมดที่จัดเตรียมในงานวิจัยเพื่อพิสูจน์ยืนยันส่วนประกอบของเส้นใยและใช้ในการจัดกลุ่มของผ้าของโดยส่งทดสอบไปที่ศูนย์วิเคราะห์ทดสอบ สิ่งทอสถาบันพัฒนาอุตสาหกรรมสิ่งทอโดยระบุการทดสอบตามมาตรฐาน มอก. 121 เล่ม 26:2552 (Thai Industrial Standard: TIS, Standards No.121 part 26-2552) ที่ว่าด้วยวิธีทดสอบหาปริมาณของเส้นใย 2 ชนิด ที่ผสมกันของผลิตภัณฑ์สิ่งทอ โดยกำหนดเครื่องมือ สารเคมีและวิธีเตรียม การชักตัวอย่าง และการเตรียมตัวอย่าง

3.1.3.3. การออกแบบตัวบรรจุครอบสำหรับเซนเซอร์ NeoSpectra-Micro และบอร์ดสมองกลฝังตัว (Raspberry Pi Zero) เพื่อช่วยในการป้องกันแสงรบกวนจากภายนอกและ ทำให้การวัดข้อมูลสเปกตรัมกับตัวอย่างผ้าคงที่ประมาณ 1 เซนติเมตรดังภาพ 7 (ก) และสามารถวางบนตัวอย่างผ้าที่ตามตำแหน่งทดสอบที่กำหนดไว้จำนวน 10 ตำแหน่งดังภาพ 7 (ข)



(ก) ตัวบรรจุครอบเซนเซอร์และการจัดเก็บ (ข) ตำแหน่งการวัดสเปกตรัม

ภาพ 7 การวัดและจัดเก็บข้อมูลสเปกตรัมบนตัวอย่างผ้า

3.1.3.4. เปรียบเทียบผลค่าการดูดกลืนแสงบนวัสดุที่แตกต่างกัน 2 ชนิด คือ บนแผ่นแพลตอคิลิกสีดำด้านและวัสดุแผ่นรองรีด โดยนำตัวอย่างผ้าที่ใช้ทดสอบเก็บครั้งตรึงบนวัสดุแต่ละชนิดเพื่อวัดข้อมูลสเปกตรัมบนผ้าและเปรียบเทียบผลค่าการดูดกลืนแสง ซึ่งอาจจะเกิดผลของกระเจิงหรือสะท้อนของแสงของวัสดุรองรีด รวมถึงให้ได้ข้อมูลสเปกตรัมที่อยู่ในสภาพแวดล้อมใกล้เคียงกับการนำไปใช้งานจริง

3.1.3.5. จัดเก็บข้อมูลโดยดึงค่าข้อมูลสเปกตรัมจากเซนเซอร์ที่อยู่ในรูปแบบของชุดข้อมูลค่าการดูดกลืนแสง (Absorbance) ในช่วงความยาวคลื่น 1350 ถึง 2500 นาโนเมตร ที่มีจำนวน 65 ข้อมูลต่อสเปกตรัม พร้อมกับข้อมูลชนิดผ้า สีผ้า ตำแหน่งที่เก็บและกลุ่มของชนิด เส้นใย จากแต่ละตัวอย่างผ้าที่ทดสอบทั้ง 10 ตำแหน่งการวัด เพื่อทดสอบความแปรปรวนที่อาจ จะเกิดขึ้นจากการวัดหรือวัสดุ ทำให้ได้ข้อมูลสเปกตรัมตัวอย่างผ้าที่ใช้ทดสอบ 960 ตัวอย่างสัญญาณสเปกตรัม จากนั้น

ทำการบันทึกข้อมูลในรูปแบบไฟล์ CSV (Comma-Separated Value) เก็บไว้ในบอร์ดสมองกลฝังตัว เพื่อนำไปใช้ในขั้นตอนการวิเคราะห์ข้อมูลต่อไป

3.1.4. การวิเคราะห์ข้อมูล

3.1.4.1. เปรียบเทียบผลลัพธ์ของจำนวนข้อมูลต่อการสแกน เนื่องจากเซนเซอร์ NeoSpectra-Micro ใช้ในการทำงานวิจัยสามารถกำหนดความละเอียดหรือจำนวนข้อมูลต่อการสแกนได้ 7 ตัวเลือก คือ 64, 128, 256, 512, 1024, 2048 และ 4096 ข้อมูลต่อสเปกตรัม จึงทำการเปรียบเทียบผลลัพธ์สเปกตรัมของตัวอย่างผ้าเดียวกัน เพื่อใช้ในการพิจารณาความละเอียดที่จะเลือกใช้ ซึ่งจะมีผลต่อทรัพยากรและเวลาในการประมวลผลแบบจำลองและอัลกอริทึมการจำแนกที่จะพัฒนา

3.1.4.2. เปรียบเทียบผลลัพธ์ของสเปกตรัมที่มีต่อตำแหน่งการสแกนที่จุดแตกต่างกัน เพื่อวิเคราะห์ความแปรปรวนหรือความแม่นยำในการทดลองซ้ำว่าตำแหน่งต่าง ๆ ของผ้าตัวอย่างมีผลกระทบต่อข้อมูลสเปกตรัมหรือไม่โดยทำการเก็บข้อมูลตัวอย่างละ 10 ตำแหน่งและนำมาวิเคราะห์หาค่าเบี่ยงเบนมาตรฐานของแต่ละเลขคลื่น (wavenumber) ด้วย ค่าส่วนเบี่ยงเบนมาตรฐาน (standard deviation)

3.1.4.3. เปรียบเทียบผลลัพธ์ของสเปกตรัมที่มีผลต่อวัสดุรองรีด ตามวัตถุประสงค์การวิจัยที่ไม่ต้องการจำแนกชนิดของผ้าด้วยข้อมูลสเปกตรัม จะนำไปใช้ในสภาพแวดล้อมการทำงานบนพื้นผิวของวัสดุที่แตกต่างกันไป จึงออกแบบการทดสอบเพื่อเปรียบเทียบผลกระทบของสเปกตรัมที่เปลี่ยนแปลงไปบนพื้นผิว 3 ชนิด คือ 1) บนแผ่นพลาสติก สีดำด้าน 2) บนโต๊ะรีดผ้าทั่วไป และ 3) บนโต๊ะรีดผ้าทั่วไปแต่มีการคลุมด้วยแผ่นรองรีดสะท้อนความร้อน

3.1.4.4. เปรียบเทียบผลลัพธ์ของสเปกตรัมที่มีผลต่อสีและกลุ่มเส้นใย ผ้าตัวอย่างแต่ละชนิดที่ใช้ทดสอบจะมีสีที่แตกต่างกันจำนวน 3 สี และทำการเก็บข้อมูล ณ ตำแหน่งที่แตกต่างกันจำนวน 10 ตำแหน่งเพื่อวิเคราะห์ดูความแปรปรวนที่อาจเกิดจากตำแหน่งการสแกน และทำซ้ำบนพื้นผิววัสดุทั้ง 3 ชนิดอีกครั้ง

3.1.5. การพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใย

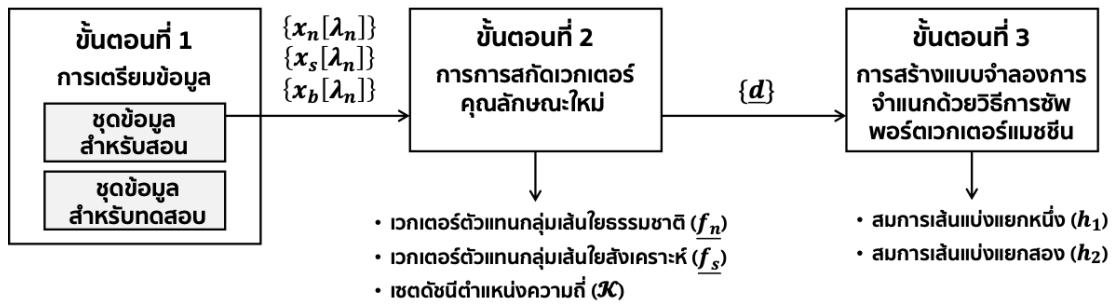
จากการวิเคราะห์ข้อมูลสเปกตรัมจากที่วัดและเก็บข้อมูลด้วยเซนเซอร์ Neo-Spectra Micro พบว่า ผ้าแต่ละกลุ่มเส้นใยมีรูปแบบของสัญญาณที่คล้ายกันแต่มีค่าการดูดกลืนแสง (absorbance) แตกต่างกันไปในแต่ละช่วงความยาวคลื่น ซึ่งอาจเกิดจากลักษณะพื้นผิว ขนาดเส้นใยสีและความหนาของผ้าที่แตกต่างกัน หรือ ความคาดเคลื่อนจากการวัดในแต่ละตำแหน่งในรูปแบบ

ของสัญญาณรบกวน ผู้วิจัยจึงได้พัฒนาอัลกอริทึมในการจำแนกสิ่งทอ ตามชนิดของเส้นใยโดยใช้เทคนิคทางการประมวลผลสัญญาณดังนี้

3.1.5.1. งานวิจัย “การปรับปรุงสัญญาณสำหรับอัลกอริทึมการจำแนกประเภทสิ่งทอจากเส้นใยธรรมชาติ” (วชิระและสุชาติ, 2565, หน้า 161) ที่เสนออัลกอริทึมการปรับปรุงสัญญาณสเปกตรัมทำให้สามารถลดค่าความแปรปรวนของแต่ละสัญญาณในกลุ่มตัวอย่างผ้าเดียวกันและค่าพลังงานของลำดับสเปกตรัมเท่ากัน จากนั้นนำไปสร้างแบบจำลองการจำแนกสิ่งทอโดยใช้ค่าพารามิเตอร์ขีดกั้นแบบแข็งซึ่งเกิดจากค่าต่ำสุดของค่าสหสัมพันธ์ไขว้กลุ่มตัวอย่าง ผ้าเส้นใยธรรมชาติ ทำให้แบบจำลองที่พัฒนาสามารถจำแนกประเภทสิ่งทอจากเส้นใยธรรมชาติและเส้นใยสังเคราะห์ได้โดยมีค่าเฉลี่ยความถูกต้อง (Accuracy) ของการทำนายทุกคลาสอยู่ที่ 0.937 ± 0.002 และมีค่าเฉลี่ยความถูกต้องสูงขึ้นเป็น 0.997 ± 0.002 หลังผ่านการปรับปรุงสัญญาณ

3.1.5.2. งานวิจัย “Matched Filter Detector for Textile Fiber Classification of Signals with Near-Infrared Spectrum” (Yammen & Limsripraphan, 2022) ที่เสนอการพัฒนาตัวกรองจับคู่ (Matched Filter) จากสัญญาณ NIR สเปกตรัมที่ผ่านนอร์มอลไลซ์สัญญาณด้วยวิธีแอลทูนอร์ม จากกลุ่มตัวอย่างผ้าเส้นใยธรรมชาติและกลุ่มตัวอย่างเส้นใยสังเคราะห์ จากนั้นนำไปสร้างแบบจำลองการจำแนกโดยใช้ผลลัพธ์ของสัญญาณนำเข้าใด ๆ กับตัวกรองจับคู่ทั้งสอง เพื่อนำมาวิเคราะห์หาค่า Threshold ที่เหมาะสมจำนวน 4 ตัว ทำให้แบบจำลองที่พัฒนาสามารถจำแนกประเภทสิ่งทอออกเป็น 3 กลุ่ม คือ เส้นใยธรรมชาติ เส้นใยสังเคราะห์และเส้นใยผสม โดยมีค่าความถูกต้องรวมของทุกคลาสอยู่ที่ 0.9922 ± 0.078 เมื่อใช้อัตราส่วนการเทรนและทดสอบที่ 80:20 และลดลงเหลือ 0.9899 ± 0.087 เมื่อใช้อัตราส่วนการเทรนและทดสอบที่ 60:40 และเมื่อพิจารณาแยกคลาส พบว่า ค่าความแม่นยำ (Precision) ของเส้นใยธรรมชาติและเส้นใยผสมได้ค่าเฉลี่ยจากการสุ่มข้อมูลเพื่อทำซ้ำจำนวน 10 รอบอยู่ที่ 0.9824 ± 0.0270 และ 0.9781 ± 0.0150 ตามลำดับ

งานวิจัยทั้งสองแสดงให้เห็นว่าเทคนิคทางการประมวลผลสัญญาณสามารถใช้จำแนกประเภทสิ่งทอจากข้อมูลสเปกตรัมที่วัดได้จากเซนเซอร์ Neo-Spectra Micro ออกเป็น 3 กลุ่ม ได้แต่เมื่อพิจารณาแยกคลาส พบว่า ค่าความแม่นยำ (Precision) ของเส้นใยธรรมชาติและเส้นใยผสมยังมีความผิดพลาดและอาจเพิ่มมากขึ้นเมื่อเจอชุดข้อมูลใหม่ รวมถึงข้อมูลสัญญาณนำเข้าใด ๆ มีจำนวน 65 ข้อมูลต่อสัญญาณ ทำให้ต้องการใช้ทรัพยากรและระยะเวลาในการประมวลผลสูง ซึ่งอาจทำให้แบบจำลองที่พัฒนาไม่เหมาะสมในการทำงานบนระบบสมองกลฝังตัว จึงปรับปรุงการพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยโดยมีขั้นตอนหลัก จำนวน 3 ขั้นตอน ดังภาพ 8 ซึ่งรายละเอียดดังนี้



ภาพ 8 ขั้นตอนพัฒนาอัลกอริทึมจำแนกสิ่งทอตามชนิดเส้นใย

ขั้นตอนที่ 1: การเตรียมข้อมูล

ขั้นตอนที่ 1.1 การเตรียมสัญญาณสเปกตรัมนำเข้า $\{x[\lambda_n]\}$

นำข้อมูลสเปกตรัมของผ้าตัวอย่างทั้ง 3 กลุ่มเส้นใยที่ได้จากการจัดเก็บแปลงให้อยู่ในรูปลำดับข้อมูล $\{x[\lambda_n]\}$ ของค่าดูดกลืนแสง (absorbance) และความยาวคลื่น (λ_n) โดยที่ n แทนดัชนีของค่าดูดกลืนแสงในย่านใกล้อินฟราเรดช่วง 1350 ถึง 2500 นาโนเมตรและ $n \in \{0,1,2, \dots, 64\}$ เพื่อใช้เป็นลำดับข้อมูลสัญญาณสเปกตรัมนำเข้าใด ๆ ได้จากตัวอย่างผ้าที่ใช้ทดสอบ 96 ผืน รวม 960 ตัวอย่างสัญญาณสเปกตรัม สำหรับใช้สร้างแบบจำลองและทดสอบการจำแนกประเภทสิ่งทอตามชนิดของเส้นใย โดยกำหนดให้ $\{x_n[\lambda_n]\}$ แทนลำดับข้อมูลสัญญาณสเปกตรัมกลุ่มเส้นใยธรรมชาติจำนวน 210 สัญญาณ $\{x_s[\lambda_n]\}$ แทนลำดับข้อมูลสัญญาณสเปกตรัมกลุ่มเส้นใยสังเคราะห์จำนวน 480 สัญญาณและ $\{x_b[\lambda_n]\}$ แทนลำดับข้อมูลสัญญาณสเปกตรัมกลุ่มเส้นใยผสมจำนวน 270 สัญญาณ

ขั้นตอนที่ 1.2 แบ่งชุดข้อมูลสำหรับชุดสอนและทดสอบแบบจำลอง (Train: Test)

ทำการแบ่งชุดข้อมูลสัญญาณสเปกตรัมในแต่ละกลุ่มเส้นใยสำหรับใช้ในการสร้างและทดสอบแบบจำลองการจำแนกในอัตราส่วนที่แตกต่างกัน 3 อัตราส่วน คือ 60:40, 70:30 และ 80:20 และการแบ่งแต่ละอัตราส่วนจะทำการสุ่มเลือกข้อมูลสัญญาณสเปกตรัมซ้ำจำนวน 10 รอบ โดยจะใช้ข้อมูลจากชุดสำหรับสอนแบบจำลองในส่วนซอฟต์แวร์ที่จะพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าและใช้ชุดข้อมูลสำหรับทดสอบแบบจำลองในส่วนส่วนการวัดประสิทธิภาพอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า

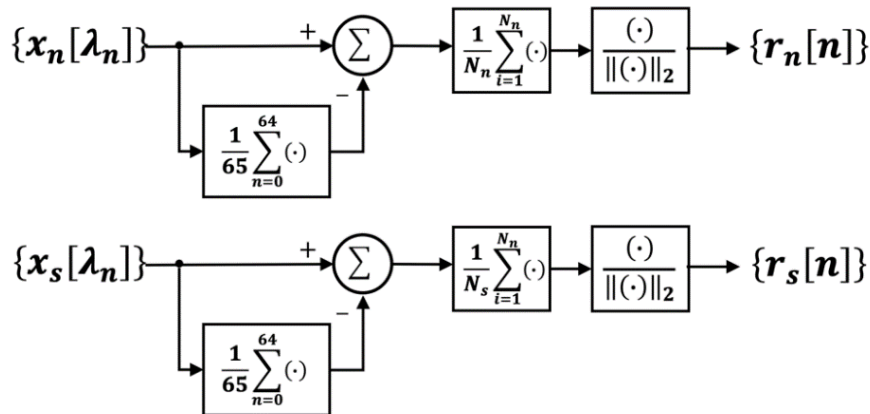
ขั้นตอนที่ 2: วิธีการสกัดเวกเตอร์คุณลักษณะใหม่

นำข้อมูลจากชุดสำหรับสอนแบบจำลองเพื่อสกัดหาเวกเตอร์คุณลักษณะใหม่ด้วยการวิเคราะห์ในโดเมนความถี่อย่างการแปลงฟูเรียร์ (The Fourier Transform: FT) ซึ่งเป็นวิธีการที่นิยมใช้ในการสกัดคุณลักษณะใหม่ในงานด้านการประมวลผลสัญญาณดิจิทัล (Ghaderi & Kabiri, 2012; Sumarno, 2020; Zhou et al., 2011) เพื่อให้ได้เวกเตอร์คุณลักษณะใหม่ที่มีจำนวนข้อมูลลดลง

ก่อนนำไปใช้เป็นอินพุตในการสร้างแบบจำลองด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีนแบบหลายคลาส (multi-Class SVM) โดยมีรายละเอียดดังนี้

ขั้นตอนที่ 2.1 สร้างสัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัมของกลุ่มเส้นใยธรรมชาติ และกลุ่มเส้นใยสังเคราะห์


ทำการสร้างตัวแทนสัญญาณของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ เพื่อนำมาใช้เปรียบเทียบและวิเคราะห์หาตำแหน่งที่มีความแตกต่างกันอย่างมีนัยสำคัญใน โดเมนความถี่ โดยใช้สัญญาณนำเข้า $\{x_n[\lambda_n]\}$ และ $\{x_s[\lambda_n]\}$ โดยที่ $n \in \{0,1,2, \dots, 64\}$ และมีจำนวนข้อมูล N_n และ N_s ตามลำดับ มาทำการนอร์มอลไลซ์สัญญาณเพื่อลดค่าความแปรปรวนและทำให้ค่าพลังงานของลำดับสเปกตรัมเท่ากัน (Yammen & Limsripraphan, 2022) ด้วยการลบแต่ละสัญญาณด้วยค่าเฉลี่ยของตัวสัญญาณ แล้วนำมาหาค่าสัญญาณเฉลี่ยของแต่ละกลุ่มและหารด้วยแอลทูนอร์ของตัวสัญญาณเฉลี่ย ทำให้ได้สัญญาณตัวแทนของกลุ่มเส้นใยธรรมชาติ $\{r_n[n]\}$ และกลุ่มเส้นใยสังเคราะห์ $\{r_s[n]\}$ ดังแสดงในภาพ 9



ภาพ 9 การสร้างสัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัม

ขั้นตอนที่ 2.2 วิเคราะห์สัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัมในโดเมนความถี่

เพื่อให้สอดคล้องประเด็นปัญหาของงานวิจัยที่ต้องลดจำนวนข้อมูลสัญญาณสเปกตรัม แต่ยังบอกได้ถึงคุณลักษณะเด่นของสัญญาณสเปกตรัมแต่ละกลุ่มเส้นใยที่สามารถใช้ใน การจำแนกกลุ่มของเส้นใยได้อย่างมีประสิทธิภาพ ผู้วิจัยจึงต้องการสร้างเวกเตอร์ตัวแทนคุณลักษณะสร้างเวกเตอร์ตัวแทนคุณลักษณะของสัญญาณในกลุ่มเส้นใยธรรมชาติและ กลุ่มเส้นใยสังเคราะห์ ในโดเมนความถี่ และเลือกเฉพาะดัชนีความถี่ที่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างทั้งสองกลุ่มมาสร้างเป็นเซต \mathcal{X} และนำไปใช้ในขั้นตอนการสร้างเวกเตอร์ตัวแทนคุณลักษณะต่อไปโดยมีการทำงานดังภาพ 10 และรายละเอียดดังนี้



ภาพ 10 การวิเคราะห์ข้อมูลในโดเมนความถี่เพื่อสกัดคุณลักษณะเด่นสัญญาณ

ขั้นตอนที่ 2.2.1 แปลงสัญญาณตัวแทนกลุ่มให้อยู่ส่วนจริงของโดเมนความถี่

ทำการแปลงสัญญาณนอร์มอลไลซ์สเปกตรัมตัวแทนกลุ่มเส้นใยธรรมชาติ $\{r_n[n]\}$ และกลุ่มเส้นใยสังเคราะห์ $\{r_s[n]\}$ ให้อยู่ในโดเมนความถี่ของสเปกตรัมสัญญาณนั้น โดยใช้ อนุกรมฟูเรียร์ของลำดับคาบ (Discrete Fourier Transform, DFT) ที่แปลงสัญญาณอินพุตในโดเมนเวลา $\{x[n]\}$ โดยที่ $n \in \{0, 1, 2, \dots, 64\}$ เป็นสัญญาณเอาต์พุตในโดเมนความถี่ $\{X[k]\}$ โดยที่ $k \in \{0, 1, 2, \dots, 64\}$ ซึ่งผลลัพธ์ของการแปลงจะประกอบไปด้วยส่วนจริงและส่วนจินตภาพ ซึ่งในงานวิจัยเลือกใช้เฉพาะส่วนจริงของผลลัพธ์ของการแปลง DFT โดยนิยามเรียกว่า RDFT (the real part of Discrete Fourier Transform) แทนด้วยสัญลักษณ์ $\{ReX[k]\}$ ดังแสดงในสมการที่ 3-1

$$ReX[k] = \sum_{n=0}^{N-1} x[n] \cos(2\pi nk/N) \quad (3-1)$$

ทำให้หลังการแปลง RDFT จะได้สัญญาณตัวแทนกลุ่มที่อยู่ในโดเมนความถี่ของกลุ่มเส้นใยธรรมชาติ $\{ReR_n[k]\}$ และสัญญาณตัวแทนกลุ่มเส้นใยสังเคราะห์ $\{ReR_s[k]\}$ เพื่อนำไปใช้เปรียบเทียบหาตำแหน่งความถี่ k ที่ใช้สร้างเวกเตอร์ตัวแทนกลุ่ม

ขั้นตอนที่ 2.2.2 หาตำแหน่งความถี่ที่ใช้สร้างเวกเตอร์ตัวแทนคุณลักษณะ

ลำดับข้อมูลของสัญญาณ $\{ReR_n[k]\}$ และ $\{ReR_s[k]\}$ หลังการแปลงจะมีความสมมาตรกัน ณ ตำแหน่งที่ $N - 1/2 = 32$ ตามคุณสมบัติของอนุกรมฟูเรียร์ของลำดับคาบในกรณีที่มี N เป็นเลขคี่ จึงเลือกใช้ข้อมูลเฉพาะส่วนในตำแหน่งที่ $k \in \{0, 1, 2, \dots, 32\}$ มาเปรียบเทียบหาตำแหน่งความถี่ k ใด ๆ ของสัญญาณทั้งสองที่มีค่าเครื่องหมายของค่า RDFT แตกต่างกัน และมีค่าความต่างของค่า RDFT ซึ่งแทนด้วยสัญลักษณ์ Δ_k มากกว่าค่า -3dB ทำให้หลังเสร็จสิ้นขั้นตอนที่ 2.2.2 จะได้ เซตดัชนีความถี่ $\mathcal{K} \in \{k_1, k_2, k_3, \dots, k_K\}$ ที่เก็บตำแหน่งความถี่ k ของสัญญาณตัวแทนกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์หลังการแปลง RDFT ที่แตกต่างกันอย่างมีนัยสำคัญ

ขั้นตอนที่ 2.3 สร้างเวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์

นำเซต \mathcal{K} ที่มีความแตกต่างกันอย่างมีนัยสำคัญระหว่างทั้งสองกลุ่มสัญญาณที่ได้จากการวิเคราะห์ในโดเมนความถี่มาสร้างเป็นเวกเตอร์ตัวแทนกลุ่มซึ่งจะแสดงให้เห็นระยะห่างระหว่างเวกเตอร์โดยใช้ค่าลำดับข้อมูลของสัญญาณ $\{ReR_n[k]\}$ และ $\{ReR_s[k]\}$ ที่เลือกเฉพาะ ตำแหน่ง k ใด ๆ ในเซต \mathcal{K} ดังสมการที่ 3-2

$$\underline{f}_n = \begin{bmatrix} ReR_n[k_1] \\ ReR_n[k_2] \\ \vdots \\ ReR_n[k_K] \end{bmatrix}_{K \times 1}, \underline{f}_s = \begin{bmatrix} ReR_s[k_1] \\ ReR_s[k_2] \\ \vdots \\ ReR_s[k_K] \end{bmatrix}_{K \times 1} \quad (3-2)$$

ทำให้หลังเสร็จสิ้นขั้นตอนที่ 2.3 จะได้เวกเตอร์ตัวแทนกลุ่ม $\underline{f}_n, \underline{f}_s$ ที่เป็นตัวแทนของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ตามลำดับ เพื่อนำไปใช้ในขั้นตอนการสร้างเวกเตอร์คุณลักษณะใหม่และมีจำนวนข้อมูลลดลงเมื่อเปรียบเทียบกับสัญญาณนำเข้า


ขั้นตอนที่ 2.4 สร้างเวกเตอร์คุณลักษณะใหม่

จากขั้นตอนที่ 2.3 พบว่าหลังการสกัดคุณลักษณะใหม่โดยใช้การแปลง RDFT และเลือกเฉพาะตำแหน่งความถี่ k ตามวิธีการที่นำเสนอจะได้เวกเตอร์ตัวแทนของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ ดังนั้นคณะผู้วิจัยจึงนำเสนอการสร้างเวกเตอร์คุณลักษณะใหม่ \underline{d} ซึ่งจะแสดงถึงระยะห่างระหว่างเวกเตอร์ของสัญญาณสเปกตรัมนำเข้าใด ๆ \underline{f}_x กับเวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและเวกเตอร์กลุ่มเส้นใยสังเคราะห์ โดยการใช้วิธีแอลทูนอร์มดังแสดงสมการที่ 3-3

$$\underline{d} = \begin{bmatrix} \|\underline{f}_x - \underline{f}_n\|_2^2 \\ \|\underline{f}_x - \underline{f}_s\|_2^2 \end{bmatrix}_{2 \times 1} = \begin{bmatrix} d_1 \\ d_2 \end{bmatrix} \quad (3-3)$$

โดยเวกเตอร์ของสัญญาณสเปกตรัมนำเข้าใด ๆ \underline{f}_x เกิดจากการใช้สัญญาณสเปกตรัมนำเข้าใด $\{x[n]\}$ ที่ผ่านการนอร์มอลไลซ์สเปกตรัมด้วยการลบแต่ละสัญญาณด้วยค่าเฉลี่ยของตัวสัญญาณ แล้วหารด้วยแอลทูนอร์มของตัวสัญญาณดังภาพ 11 แล้วแปลงให้อยู่ในโดเมนความถี่ด้วย RDFT ทำให้ได้ลำดับข้อมูล $\{ReX[k]\}$ จากนั้นเลือกเฉพาะตำแหน่ง k ใด ๆ ในเซต \mathcal{K} ที่ได้จากการสกัดคุณลักษณะใหม่ดังสมการที่ 3-4

$$\underline{f}_x = \begin{bmatrix} ReX[k_1] \\ ReX[k_2] \\ \vdots \\ ReX[k_K] \end{bmatrix}_{K \times 1} \quad (3-4)$$



ภาพ 11 การสร้างสัญญาณนอร์มอลไลซ์สเปกตรัมของสัญญาณนำเข้าใด ๆ

ขั้นตอนที่ 3: สร้างแบบจำลองการจำแนกด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีน

ใช้ชุดข้อมูลเวกเตอร์คุณลักษณะใหม่ \underline{d} ที่สร้างในขั้นตอนที่ 2 เพื่อสร้างแบบจำลองการจำแนกด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีนโดยทำการหาสัมประสิทธิ์ของสมการเส้นแบ่งแยก (Hyperplane) กลุ่มข้อมูลทำได้โดยการเลือกเส้นหรือระนาบแบ่งแยกประเภทข้อมูลที่เหมาะสมที่สุด ดังสมการ 3-5

$$\begin{aligned} & \text{minimize } \frac{1}{2} \|\underline{w}\|^2 \\ & \text{subject to } y(\underline{w}^T \underline{d} + b) \geq 1 \end{aligned} \quad (3-5)$$

โดยที่:

\underline{w} คือ เวกเตอร์ตั้งฉากของค่าความชันของเส้นแบ่ง

b คือ ค่าคงที่ที่ได้จากค่าของแกน y ของแต่ละข้อมูล \underline{d}

y คือ ผลลัพธ์ของการสมการเส้นแบ่งของการจำแนกแบบสองคลาสโดย $y \in \{+1, -1\}$

ซึ่งในงานวิจัยนี้ต้องการจำแนกประเภทสิ่งทอออกเป็น 3 กลุ่ม คือ เส้นใยธรรมชาติ เส้นใยสังเคราะห์และเส้นใยผสมจึงต้องใช้ซัพพอร์ตเวกเตอร์แมชชีนแบบจำแนกมากกว่าสองกลุ่ม (Multiclass Classification) และเลือกใช้วิธีการตัดแยกทีละหนึ่งต่อหนึ่ง (One-against-One) ทำให้มีจำนวนฟังก์ชันการตัดสินใจของ M คลาสเท่ากับ $M(M-1)/2 = 3$ สมการดังตาราง 8

ตาราง 8 ซัพพอร์ตเวกเตอร์แมชชีนแบบการตัดแยกทีละหนึ่งต่อหนึ่ง

$y_i = 1$	$y_i = -1$	สมการเส้นแบ่ง (Hyperplane)
กลุ่มเส้นใยธรรมชาติ	กลุ่มเส้นใยสังเคราะห์	$h_1(\underline{d}) = \underline{w}_1^T \underline{d} + b_1$
กลุ่มเส้นใยธรรมชาติ	กลุ่มเส้นใยผสม	$h_2(\underline{d}) = \underline{w}_2^T \underline{d} + b_2$

กลุ่มเส้นใยสังเคราะห์

กลุ่มเส้นใยผสม

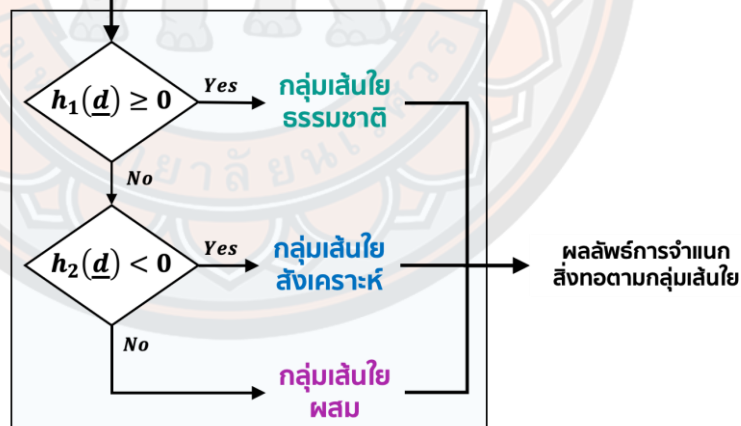
$$h_3(\underline{d}) = w_3^T \underline{d} + b_3$$

จากตาราง 8 พบว่า หากใช้วิธีการตัดแยกทีละหนึ่งต่อหนึ่ง จะเกิดการคำนวณเพื่อการจำแนกจำนวน 3 ครั้งเท่ากับจำนวนของคลาสที่ต้องการจำแนก ซึ่งอาจจะส่งผลต่อประสิทธิภาพการคำนวณเมื่อต้องใช้งานบนระบบสมองกลฝังตัวตามประเด็นปัญหาทางวิจัย ดังนั้นผู้วิจัยจึงนำเสนออัลกอริทึมจำแนกสิ่งทอที่มีเงื่อนไขการทำงานดังภาพ 12 โดยใช้ค่าพารามิเตอร์ที่เกิดจากการกำหนดเส้นแบ่งแยก (Hyperplane) จำนวน 2 สมการ ดังตาราง 9

ตาราง 9 การกำหนดกลุ่มข้อมูลเพื่อสร้างสมการเส้นแบ่งแยกอัลกอริทึมที่นำเสนอ

$y_i = 1$	$y_i = -1$	สมการเส้นแบ่ง (Hyperplane)
กลุ่มเส้นใยธรรมชาติ	กลุ่มเส้นใยสังเคราะห์ และกลุ่มเส้นใยผสม	$h_1(\underline{d}) = w_1^T \underline{d} + b_1$
กลุ่มเส้นใยธรรมชาติ และกลุ่มเส้นใยผสม	กลุ่มเส้นใยสังเคราะห์	$h_2(\underline{d}) = w_2^T \underline{d} + b_2$

เวกเตอร์คุณลักษณะใหม่

 \underline{d} 

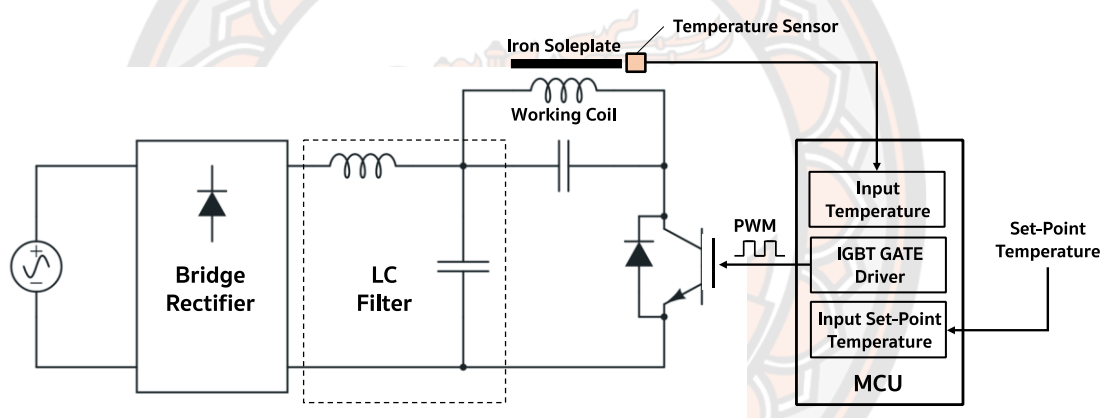
ภาพ 12 อัลกอริทึมการจำแนกสิ่งทอตามชนิดเส้นใยที่นำเสนอ

ทำให้หลังเสร็จทั้ง 3 ขั้นตอนในส่วนซอฟต์แวร์ของการพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยที่ผู้วิจัยนำเสนอ จะได้ค่าพารามิเตอร์ที่จะทำไปใช้ในการสร้างเวกเตอร์คุณลักษณะใหม่ \underline{d} จากสัญญาณนอร์มอลไลซ์สเปกตรัมสเปกตรัมนำเข้าใด ๆ ของข้อมูลชุดทดสอบแบบจำลอง อาทิเช่น เซตดัชนีความถี่ \mathcal{K} ที่เก็บตำแหน่งความถี่ที่ใช้เลือกตำแหน่งความถี่หลังการ

แปลง RDFT และค่าเวกเตอร์ตัวแทนกลุ่ม f_n, f_s ที่เป็นตัวแทนของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ตามลำดับ พร้อมสมการเส้นแบ่งแยก $h_1(d), h_2(d)$ ที่จะนำอัลกอริทึมการจำแนกสิ่งทอตามชนิดเส้นใยที่นำเสนอ เพื่อนำไปใช้หาประสิทธิภาพอัลกอริทึมในส่วน การวัดประสิทธิภาพอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้าต่อไป

3.2 ส่วนดำเนินการด้านฮาร์ดแวร์

ที่ดำเนินการพัฒนาต้นแบบเตารีดไฟฟ้าที่ทำความร้อนด้วยการเหนี่ยวนำแบบกึ่งเรโซแนนท์ (Quasi-Resonant Induction Heater) โดยใช้ไมโครคอนโทรลเลอร์ ในการควบคุมอุณหภูมิอัตโนมัติตามที่กำหนด (Set-Point Temperature) ที่ใช้ค่าการป้อนกลับจากเซนเซอร์วัดอุณหภูมิเป็นเงื่อนไขในการควบคุมการส่งงานสัญญาณพัลส์ (Pulse Width Modulation) ของวงจรถับขาเกตของอุปกรณ์เพาเวอร์ไอจีบีที (IGBT) ดังภาพ 13



ภาพ 13 ไดอะแกรมการทำงานต้นแบบเตารีดเหนี่ยวนำที่ควบคุมอุณหภูมิอัตโนมัติ

ทำการทบทวนงานวิจัยที่เกี่ยวข้องการทำความร้อนด้วยการเหนี่ยวนำและเครื่องใช้ไฟฟ้าที่ใช้หลักการทำความร้อนด้วยเทคโนโลยี Induction Heating ที่มีอยู่ในปัจจุบัน พบว่าส่วนใหญ่ใช้รูปแบบการเชื่อมต่อวงจรการเหนี่ยวนำแบบกึ่งเรโซแนนท์ (Quasi Resonant) ด้วยอุปกรณ์สวิตช์ IGBT เพียงตัวเดียว ซึ่งเป็นวงจรที่เรียบง่าย อุปกรณ์สามารถหาซื้อได้ง่าย และประหยัดอุปกรณ์มากกว่าการใช้รูปแบบการเชื่อมโยงวงจรแบบ Half-bridge หรือ Full-Bridge resonant Converter จึงดำเนินการพัฒนาต้นแบบเตารีดไฟฟ้าตามขั้นตอนดังนี้

3.2.1. ออกแบบและพัฒนางจรการเหนี่ยวนำแบบกึ่งเรโซแนนท์

ทำการออกแบบวงจรเหนี่ยวนำแบบกึ่งเรโซแนนท์ที่ใช้อุปกรณ์กำลังประเภทเพาเวอร์ไอจีบีที (IGBT: Insulated Gate Bipolar Transistor) ที่ควบคุมด้วยบอร์ดไมโครคอนโทรลเลอร์ โดยทำการทดสอบความสามารถในการทำงานของการสร้างความถี่ของสัญญาณ (Frequency) และ

ความกว้างของลูกคลื่น (Duty Cycle) ของสัญญาณพัลส์ในการขับวงจรขับขาเกต IGBT ผ่านไอซี IR2110PBF ที่ทำหน้าที่เป็น IGBT Driver และวิเคราะห์กระแสไฟฟ้าสูงสุด กระแสไฟฟ้าเฉลี่ยและระดับแรงดันคร่อมขาเกต IGBT ของวงจรที่พัฒนาขึ้น

3.2.2. เปรียบเทียบการใช้เซนเซอร์อุณหภูมิแบบสัมผัสและแบบไร้สัมผัส

ทำการเปรียบเทียบผลทดสอบการใช้งานเซนเซอร์แบบสัมผัส RTD PT100 Class A กับ เซนเซอร์ไร้สัมผัสแบบอินฟราเรด GY-906 เพื่อดูผลทดสอบระยะเวลาในการตอบสนองของอุณหภูมิที่เหมาะสมต่อระยะเวลาในการเปลี่ยนแปลงอุณหภูมิของแผ่นพื้นเตารีดที่มีความเร็วในการเปลี่ยนแปลงค่อนข้างสูง และนำเซนเซอร์ที่มีผลการตอบสนองต่ออุณหภูมิในระยะเวลาที่เหมาะสมไปใช้เป็นเซนเซอร์ในการอ่านค่าอุณหภูมิย้อนกลับในการควบคุมอุณหภูมิโดยอัตโนมัติของระบบควบคุม

3.2.3. พัฒนา Mobile Application ในการควบคุมต้นแบบเตารีดอัจฉริยะ

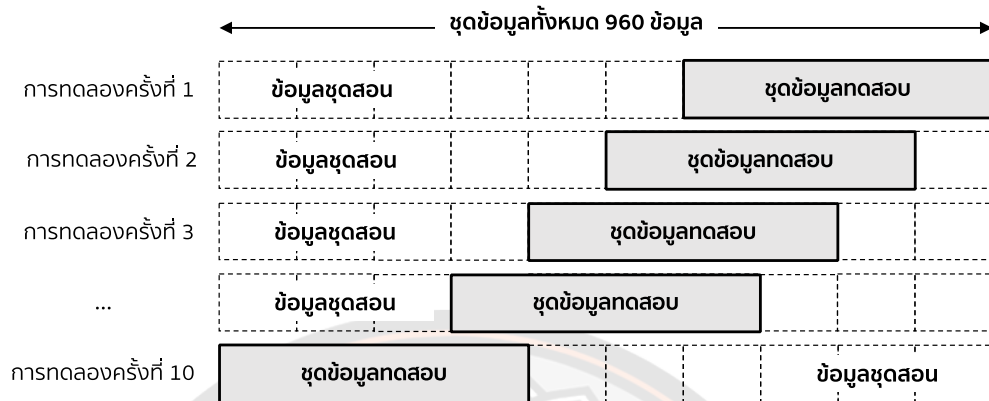
ทำการพัฒนา Mobile Application และ Web Application ที่สามารถเชื่อมต่อกับบอร์ดไมโครคอนโทรลเลอร์ของระบบควบคุมอุณหภูมิของเตารีดต้นแบบเพื่อให้ได้ต้นแบบฮาร์ดแวร์ที่สอดคล้องกับประเด็นปัญหาที่ต้องการพัฒนาเครื่องใช้ไฟฟ้าอัจฉริยะที่รองรับการทำงานแบบ IoT และใช้ Mobile Application ที่พัฒนาขึ้นในการกำหนดค่าพารามิเตอร์อินพุตของระบบในการทดสอบการควบคุมอุณหภูมิ อาทิเช่น ความกว้างลูกคลื่น (Duty Cycle) หรือ ความถี่ (Frequency) ของสัญญาณพัลส์ขับขาเกต IGBT และอุณหภูมิที่ต้องการควบคุมอัตโนมัติ รวมถึงการส่งค่าอุณหภูมิของแผ่นพื้นเตารีด สถานะการทำงานของขาเกต IGBT ไปที่ Web Application ที่ทำหน้าที่ในการเก็บ Data Log ที่จะนำไปใช้ในการวิเคราะห์การควบคุมอุณหภูมิ

3.2.4 ทดสอบการควบคุมอุณหภูมิที่แผ่นพื้นเตารีดให้อยู่ในช่วงอุณหภูมิที่กำหนดพัฒนาระบบควบคุมอุณหภูมิตามที่กำหนดโดยใช้ค่าอุณหภูมิของแผ่นพื้นเตารีดเป็นเงื่อนไขที่ป้อนกลับในการสั่งงานสัญญาณพัลส์ขับขาเกต IGBT และทดสอบหาช่วงเวลาในการทำความร้อน (Raising Up) ที่เกิดขึ้นจากความกว้างลูกคลื่น (Duty Cycle) และความถี่ (Frequency) ของสัญญาณพัลส์ขับขาเกต IGBT ที่แตกต่างกันไป

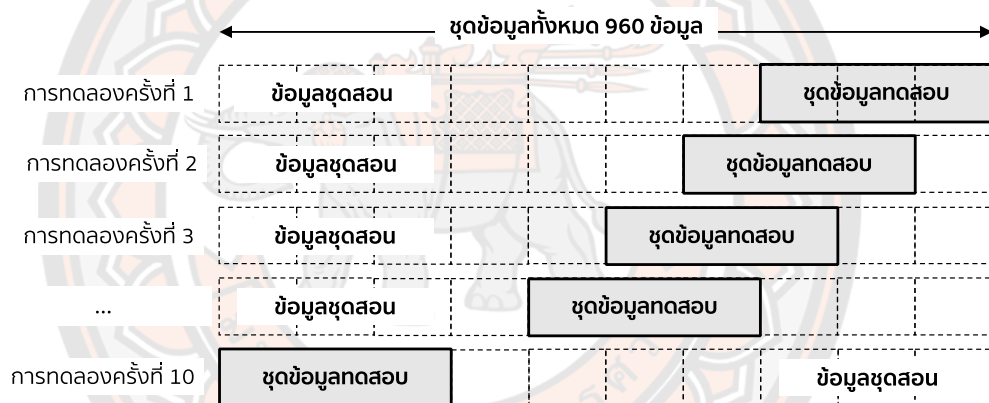
3.3 ส่วนดำเนินการวัดประสิทธิภาพอัลกอริทึมการจำแนก

เลือกใช้ชุดข้อมูลสำหรับทดสอบแบบจำลองที่แบ่งไว้ในส่วนการพัฒนาอัลกอริทึมที่งานวิจัยนี้ได้กำหนดอัตราส่วนระหว่างชุดข้อมูลสอนและชุดข้อมูลทดสอบจำนวน 3 อัตราส่วน คือ 60:40, 70:30 และ 80:20 โดยในแต่ละอัตราส่วนจะทำสุ่มข้อมูลแบบความเที่ยงตรง K กลุ่ม (K-Fold Cross Validation) จำนวน 10 ชุดเท่าๆ กัน ยกตัวอย่างเช่น ดังภาพ 14 (ก) จากจำนวนข้อมูลทั้งหมด 960 ข้อมูล จะแบ่งเป็นชุดข้อมูลสอน 60% ทำให้มีข้อมูลทั้งหมด 576 ข้อมูล และชุดข้อมูลทดสอบ 40%

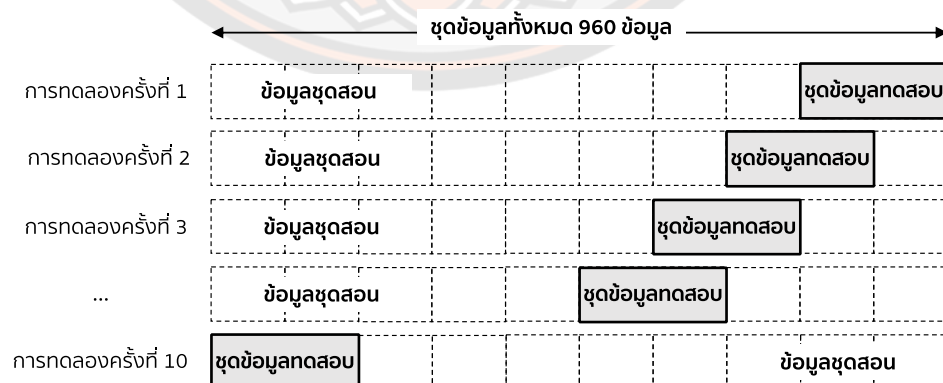
ทำให้มีข้อมูลทั้งหมด 384 ข้อมูล โดยในแต่ละรอบการทดลองครั้งที่ 1 ถึงครั้งที่ 10 จะทำการสุ่มเลือกข้อมูลที่ใช้ในการแบ่งไม่ซ้ำกับชุดเดิม



(ก) สัดส่วนชุดสอนและชุดข้อมูลทดสอบ 60:40



(ข) สัดส่วนชุดสอนและชุดข้อมูลทดสอบ 70:30

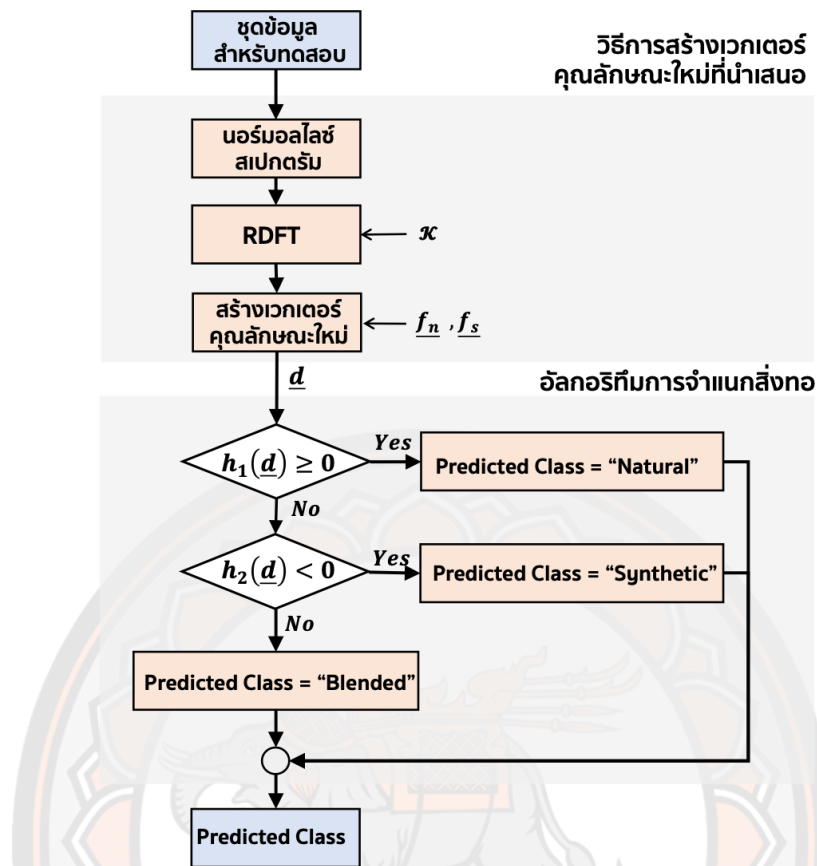


(ค) สัดส่วนชุดสอนและชุดข้อมูลทดสอบ 80:20

ภาพ 14 การแบ่งสัดส่วนชุดสอนและชุดข้อมูลทดสอบ

และในภาพ 14 (ข) แสดงการแบ่งข้อมูลอัตราส่วน 70:30 ทำให้ได้ชุดข้อมูลสอนทั้งหมด 672 ข้อมูลและชุดข้อมูลทดสอบทั้งหมด 288 ข้อมูล ส่วนในภาพ 14 (ค) แสดงการแบ่งข้อมูลในอัตราส่วน 80:20 ทำให้ได้ชุดข้อมูลสอนทั้งหมด 768 ข้อมูลและชุดข้อมูลทดสอบทั้งหมด 192 ข้อมูล โดยในทุกๆ อัตราส่วนและรอบการทดลองซ้ำจะทำการแบ่งชุดข้อมูลในแต่ละกลุ่มเส้นใยตามอัตราส่วนอีกด้วย

ในแต่ละครั้งของรอบการทดลองซ้ำของชุดข้อมูลแต่ละสัดส่วนชุดข้อมูลสอนที่ถูกแบ่งไว้ในส่วนที่การพัฒนาอัลกอริทึมของการดำเนินการวิจัย จะได้พารามิเตอร์ของอัลกอริทึมที่ได้จากการนำเสนอมาดำเนินการ 2 ขั้นตอน คือ ขั้นการสร้างเวกเตอร์คุณลักษณะใหม่ที่ทำให้การแปลงสเปกตรัมนำเข้าใด ๆ ในโดเมนความถี่และใช้เฉพาะส่วนจริง ณ ตำแหน่ง k ใด ๆ ในเซต \mathcal{K} และใช้เวกเตอร์ตัวแทน f_n, f_s และสมการเส้นแบ่ง $h_1(d), h_2(d)$ ทำให้ได้เวกเตอร์คุณลักษณะใหม่ d สำหรับชุดข้อมูลทดสอบ จากนั้นนำเวกเตอร์คุณลักษณะใหม่ d เป็นอินพุตนำเข้าสำหรับอัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใย โดยเปรียบเทียบผลลัพธ์จากสมการเส้นแบ่งแยกที่หนึ่ง $h_1(d)$ ซึ่งหากได้ผลลัพธ์เป็นบวกจะถือว่าเป็นกลุ่มเส้นใยธรรมชาติ และหากผลลัพธ์เป็นลบจะทำการเปรียบเทียบหาผลลัพธ์อีกครั้งด้วยสมการเส้นแบ่งแยกที่สอง $h_2(d)$ ซึ่งหากได้ผลลัพธ์เป็นบวกจะถือว่าเป็นกลุ่มเส้นใยผสม และหากผลลัพธ์เป็นลบจะถือว่าเป็นกลุ่มเส้นใยสังเคราะห์ ดังแสดงขั้นตอนของอัลกอริทึมดังภาพ 15



ภาพ 15 อัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า

จากนั้นใช้ผลลัพธ์จากอัลกอริทึมการจำแนกสิ่งทอตามชนิดเส้นใย เพื่อเก็บจำนวนของข้อมูลที่ทำนาย (Predicted) ถูกหรือผิดลงในตาราง Confusion Matrix แบบ Multi-Class ดังตาราง 10 โดย C11, C22 และ C33 แทน จำนวนผลลัพธ์ที่ทำนายถูกจากข้อมูลจริงของคลาสที่กำลังพิจารณา โดยหากพิจารณาจากตัวอย่างจากคลาสนุ่มเส้นใยธรรมชาติ จะสามารถอธิบายได้ว่า C11 คือ จำนวนผลลัพธ์ที่ทำนายถูกของข้อมูลจริงที่เป็นกลุ่มเส้นใยธรรมชาติ ซึ่งจะกำหนดเป็นค่า True Positive (TP) ของคลาสนุ่มเส้นใยธรรมชาติ ส่วนค่า True Negative (TN) ซึ่งหมายถึง จำนวนผลลัพธ์ที่ทำนายถูกของข้อมูลจริงที่ไม่ใช่คลาสนุ่มเส้นใยธรรมชาติและอัลกอริทึมทำนายว่าไม่ใช่คลาสนุ่มเส้นใยธรรมชาติจะเกิดจากผลรวมของ C22, C23, C32 และ C33 สำหรับผลลัพธ์ของการทำนายที่ผิด ได้แก่ ค่า False Negative (FN) ซึ่งหมายถึง จำนวนของผลลัพธ์ที่ทำนายผิดเป็นคลาสนุ่มเส้นใยธรรมชาติจากข้อมูลจริงของคลาสนุ่มเส้นใยธรรมชาติ จะเกิดจากค่าผลรวมของ C21 และ C31 ที่แทนจำนวนผลลัพธ์ที่ทำนายผิดของข้อมูลจริงที่เป็นกลุ่มเส้นใยธรรมชาติ แต่อัลกอริทึมทำนายเป็นคลาสนุ่มเส้นใยสังเคราะห์และกลุ่มเส้นใยผสม ตามลำดับ และค่า False Positive (FP) ซึ่งหมายถึง จำนวนผลลัพธ์ที่ทำนายผิดเป็นคลาสนุ่มเส้นใยธรรมชาติจากข้อมูลจริงของคลาสนุ่มเส้นใยสังเคราะห์และกลุ่มเส้นใยผสม จะเกิดจากค่าผลรวมของ C12 และ C13 ที่แทนจำนวนของ

คลาสเส้นใยสังเคราะห์และเส้นใยผสมที่ทำนายผิดเป็นคลาสเส้นใยธรรมชาติ ตามลำดับ ทำให้เมื่อนำไปแทนค่าในแต่ละคลาสของกลุ่มเส้นใยจะได้ค่า TP, FN, FP และ TN ของแต่ละคลาสดังตารางที่ 11

ตาราง 10 Confusion Matrix แบบ Multi-class Classification

		Actual Class			
		Class	Natural	Synthetic	Blended
Predicted	Class	Natural	C11	C12	C13
		Synthetic	C21	C22	C23
		Blended	C31	C32	C33

ตาราง 11 Confusion Matrix แบบ Multi-class Classification

	Natural	Synthetic	Blended
TP	C11	C22	C33
FN	C21 + C31	C12 + C32	C13 + C23
FP	C12 + C13	C21 + C23	C31 + C32
TN	C22+C23+C32+C33	C11+C13+C31+C33	C11+C12+C21+C22

จากนั้นจะใช้ค่าข้อมูลจาก Confusion Matrix ในตาราง 11 มาคำนวณวัดความแม่นยำและประเมินประสิทธิภาพของอัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใย จำแนกตามคลาส โดยใช้เครื่องมือวัดต่างๆ ดังนี้

ค่าความถูกต้อง (Accuracy)

คือ จำนวนข้อมูลที่ทำนายได้ถูกต้องของทุกคลาสตรงกับข้อมูลจริงดังสมการ

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3-6)$$

ค่าความแม่นยำ (Precision)

คือ สัดส่วนการทำนายที่ถูกต้องว่าจริงและที่เกิดขึ้นจริงจากทำนายทั้งหมดดังสมการ

$$Precision = \frac{TP}{TP + FP} \quad (3-7)$$

ค่าความระลึก (Recall)

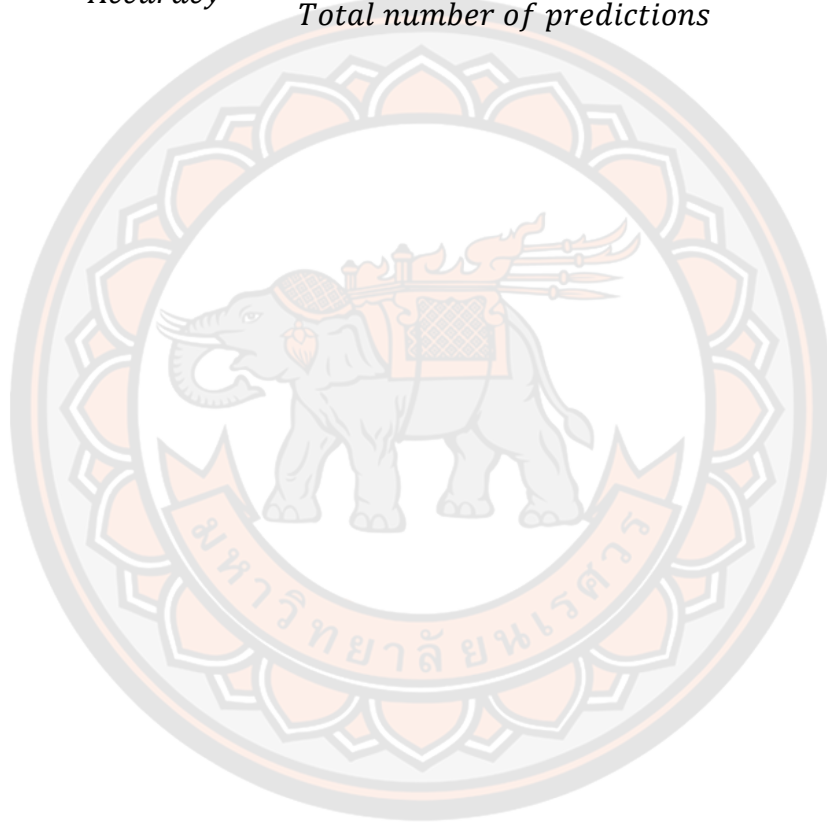
คือ สัดส่วนการทำนายที่ถูกต้องว่าจริงและที่เกิดขึ้นจริงจากข้อมูลจริงทั้งหมด ดังสมการ

$$Recall = \frac{TP}{TP + FN} \quad (3-8)$$

ค่าความถูกต้องรวมทั้งระบบ (Overall Accuracy)

คือ ค่าความถูกต้องในการทำนายของทั้งระบบรวมทุกคลาส ดังสมการ

$$Accuracy = \frac{\text{Number of corrected predictions}}{\text{Total number of predictions}} \quad (3-9)$$



บทที่ 4

ผลการวิจัย

4.1 ผลการวิจัยส่วนซอฟต์แวร์ที่พัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า

4.1.1. ผลการเก็บรวบรวมข้อมูล

4.1.1.1. ผลการเตรียมตัวอย่างผ้า การแบ่งตัวอย่างผ้าแต่ละชนิดให้มีขนาด 30 x 50 เซนติเมตร พร้อมติดหมายเลขอ้างอิง เพื่อให้มีขนาดเหมาะสมต่อการทดสอบและใช้อ้างอิงการแบ่งกลุ่มเส้นใยจากชุดสำหรับส่งทดสอบส่วนประกอบกับศูนย์วิเคราะห์ทดสอบสิ่งทอสถาบันพัฒนาอุตสาหกรรมสิ่งทอ ดังแสดงในภาพ 16



ภาพ 16 ตัวอย่างผ้าที่ใช้ในงานวิจัยและจะส่งผลไปทดสอบกับสถาบันผ้า

4.1.1.2. ผลการตรวจสอบองค์ประกอบของเส้นใยในผ้าตัวอย่าง

ศูนย์วิเคราะห์ทดสอบสิ่งทอของหน่วยงานสถาบันพัฒนาอุตสาหกรรมสิ่งทอ ได้ทดสอบตัวอย่างผ้าที่ใช้ในงานวิจัยตามมาตรฐาน มอก. 121 เล่ม 26-2552 (สำนักงานมาตรฐานผลิตภัณฑ์อุตสาหกรรม, 2552) ที่ว่าด้วยวิธีการทดสอบหาปริมาณของเส้นใย 2 ชนิดที่ผสมกันของผลิตภัณฑ์สิ่งทอ โดยกำหนดเครื่องมือ สารเคมีและวิธีเตรียม การชักตัวอย่าง และการเตรียมตัวอย่าง โดยใช้วิธีการทดสอบคำนวณค่ารวมความชื้นรีแกน (Moisture Regain) และใช้ค่าความชื้นรีแกนอ้างอิงในการทดสอบดังนี้ เส้นใยสแปนเด็กซ์ (Spandex), เส้นใยโพลีเอสเตอร์ (Polyester), เส้นใยฝ้าย (Cotton) และ ไหมสังเคราะห์เรยอน (Rayon) โดยมีค่าเท่ากับ 1.3, 1.5 , 8.5 และ 13.0 ตามลำดับ ทำให้ได้ผลลัพธ์ส่วนประกอบแต่ละเส้นใยดังตาราง 12

ตาราง 12 ผลการทดสอบองค์ประกอบของเส้นใยในผ้าตัวอย่าง

หมายเลขผ้าตัวอย่าง ที่อ้างอิงในการส่งทดสอบ	ส่วนประกอบเส้นใยผ้า (%)			
	ชนิดเส้นใยธรรมชาติ		ชนิดเส้นใยสังเคราะห์	
	Cotton	Rayon	Polyester	Spandex
R 0207-1/65	100	-	-	-
R 0207-2/65	100	-	-	-
R 0207-3/65	92	8	-	-
R 0207-4/65	46	54	-	-
R 0207-5/65	100	-	-	-
R 0207-6/65	100	-	-	-
R 0207-7/65	100	-	-	-
R 0207-11/65	-	-	100	-
R 0207-12/65	-	-	100	-
R 0207-13/65	-	-	100	-
R 0207-14/65	-	-	100	-
R 0207-15/65	-	-	100	-
R 0207-16/65	-	-	100	-
R 0207-17/65	-	-	100	-
R 0207-18/65	-	-	100	-
R 0207-19/65	-	-	100	-

ตาราง 12 (ต่อ)

หมายเลขผ้าตัวอย่าง ที่อ้างอิงในการส่งทดสอบ	ส่วนประกอบเส้นใยผ้า (%)			
	ชนิดเส้นใยธรรมชาติ		ชนิดเส้นใยสังเคราะห์	
	Cotton	Rayon	Polyester	Spandex
R 0207-20/65	-	-	100	-
R 0207-21/65	-	-	100	-
R 0207-22/65	-	-	100	-
R 0207-23/65	-	-	100	-
R 0207-24/65	-	-	94	6
R 0207-25/65	-	-	95	5
R 0207-29/65	-	-	100	-
R 0207-4/65	62	6	32	-
R 0207-35/65	52	-	48	-
R 0207-28/65	48	-	52	-
R 0207-34/65	-	36	64	-
R 0207-8/65	34	-	66	-
R 0207-27/65	34	-	66	-
R 0207-26/65	35	-	65	-
R 0207-11/65	-	36	64	-
R 0207-30/65	17	-	83	-

จากผลการทดสอบองค์ประกอบของเส้นใยในผ้าตัวอย่างดังตาราง 12 ทำให้สามารถแบ่งตัวอย่างผ้าออกเป็น 3 กลุ่ม โดยใช้หลักเกณฑ์ดังนี้ ผ้าที่เกิดจากเส้นใยฝ้าย (Cotton) หรือ เส้นใยเรยอน (Rayon) จะถูกกำหนดเป็นกลุ่มเส้นใยธรรมชาติ (Natural Fibers) ในขณะที่ตัวอย่างผ้าที่ประกอบไปด้วยเส้นใยโพลีเอสเตอร์ (Polyester) หรือเส้นใยสแปนเด็กซ์ (Spandex) จะถูกกำหนดเป็นกลุ่มเส้นใยสังเคราะห์ (Synthetic Fibers) และตัวอย่างผ้าที่เกิดจากผสมกันของเส้นใยทั้งสองกลุ่มจะถูกกำหนดเป็นกลุ่มเส้นใยผสม (Blended Fibers) ทำให้รวมทั้งหมดมีตัวอย่างผ้าที่ใช้ในการวิจัยคือ กลุ่มเส้นใยธรรมชาติจำนวน 7 ชนิดผ้า กลุ่มเส้นใยสังเคราะห์จำนวน 16 ชนิดผ้า และกลุ่มเส้นใยผสมจำนวน 9 ชนิดผ้า ที่มีสัดส่วนระหว่างเส้นใยธรรมชาติต่อเส้นใยสังเคราะห์ที่แตกต่างกัน 7


สัดส่วน คือ 68:32, 52:48, 48:52, 36:64, 35:65, 34:66 และ 17:83 ซึ่งแต่ละชนิดผ้ามีสีที่แตกต่างกันจำนวน 3 สี ทำให้สามารถสรุปจำนวนตัวอย่างผ้าที่ใช้ในงานวิจัยดังตาราง 13

ตาราง 13 ผลการจำแนกกลุ่มเส้นใยของผ้าตัวอย่างที่ใช้ทดสอบวิจัย

กลุ่มเส้นใย	จำนวนชนิดผ้า	จำนวนผ้าตัวอย่าง (ผืน)
กลุ่มเส้นใยธรรมชาติ	7	21
กลุ่มเส้นใยสังเคราะห์	16	48
กลุ่มเส้นใยผสม	9	27
รวมตัวอย่างผ้าทั้งหมด	32	96

4.1.1.3. ผลการการออกแบบตัวบรรจุครอบเซนเซอร์

ภาพ 17 (ก) แสดงตัวบรรจุครอบที่ออกแบบและสร้างขึ้นด้วยเครื่องพิมพ์ 3 มิติ เพื่อทำการบรรจุเซนเซอร์ NeoSpectra-Micro ที่ทำการเชื่อมต่อกับบอร์ดสมองกลฝังตัว (Raspberry Pi Zero) ดังแสดงในภาพ 17 (ข) เพื่อช่วยในการป้องกันแสงรบกวนจากภายนอก และทำให้การวัดข้อมูลสเปกตรัมกับตัวอย่างผ้าคงที่ประมาณ 1 เซนติเมตร และสะดวกในการเปลี่ยนแปลงตำแหน่งการวัดสัญญาณสเปกตรัม



(ก) ตัวครอบเซนเซอร์ NeoSpectra-Micro เพื่อป้องกันแสงรบกวนจากภายนอก




(ข) เซนเซอร์ NeoSpectra-Micro ที่เชื่อมต่อกับบอร์ดสมองกลฝังตัว

ภาพ 17 ตัวบรรจุและเซนเซอร์ NeoSpectra-Micro

4.1.1.4. ผลการจัดเก็บข้อมูลสเปกตรัมบนวัสดุที่แตกต่างกัน

ภาพ 18 (ก) แสดงการเก็บวัดข้อมูลสเปกตรัมจากเซนเซอร์ที่บรรจุอยู่ในตัวครอบที่ ออกแบบบนวัสดุแผ่นพลาสติกคลิกลีสีดำด้านที่ออกแบบให้สามารถนำผ้าตัวอย่างใช้ทดสอบการวัดค่า การดูดกลืนแสงของผ้าตัวอย่าง เพื่อนำไปเปรียบเทียบกับวัสดุแผ่นรองรีดผ้าที่วางบนโต๊ะรีดผ้าดังภาพ 18 (ข) ที่จะให้ข้อมูลสเปกตรัมที่อยู่ในสภาพแวดล้อมใกล้เคียงกับการนำไปใช้งานจริง ซึ่งวัสดุรองรีด ทั้งสองชนิดอาจทำให้ผลของกระเจิงหรือค่าดูดกลืนแสงของผ้าตัวอย่างที่แตกต่างกัน



(ก) แผ่นพลาสติกคลิกลีสีดำด้าน




(ข) วัสดุแผ่นรองรีดผ้า

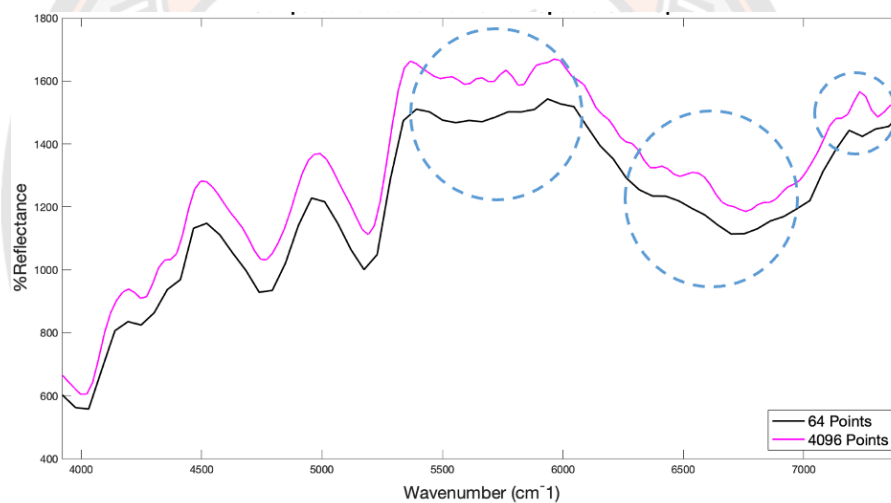
ภาพ 18 การเก็บข้อมูลสเปกตรัมของตัวอย่างผ้าบนวัสดุรอง

4.1.2. ผลการวิเคราะห์ข้อมูล

4.1.2.1 ผลการเปรียบเทียบผลลัพธ์ของจำนวนข้อมูลต่อการสแกน จากภาพ 19พบว่า ลักษณะของสเปกตรัมในแต่ละความละเอียดการสแกนมีรูปแบบคล้ายคลึงกัน แต่มีรายละเอียดที่ แตกต่างกันในบางช่วงเลขคลื่น โดยเฉพาะเมื่อพิจารณาจากการเปรียบเทียบ ในภาพ 20 ซึ่งเป็นการ เปรียบเทียบระหว่างค่าความละเอียดสูงสุดและต่ำสุด พบว่า ช่วงเลขคลื่น ที่ 5,500 – 6,500 หรือ 6,500 - 7,400 และ 7,000 – 7,500 มีลักษณะของรูปแบบสเปกตรัมที่แตกต่างกันซึ่งอาจส่งผล ต่อประสิทธิภาพของแบบจำลองการจำแนก แต่เพื่อความเหมาะสมในการใช้งานบนระบบสมองกลฝัง ตัวที่จะมีทรัพยากรและเวลาในการประมวลผลจำกัดจึงเลือกความละเอียดการสแกนต่ำที่สุด



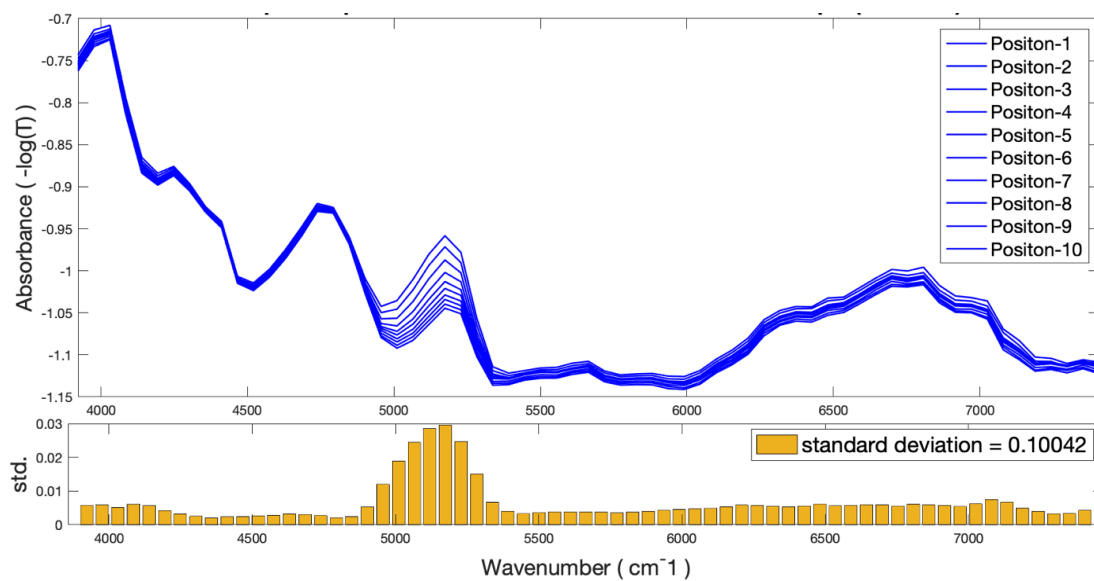
ภาพ 19 เปรียบเทียบสเปกตรัมผ้าตัวอย่างที่ความละเอียดการสแกนต่างกัน



ภาพ 20 เปรียบเทียบสเปกตรัมผ้าตัวอย่างที่ความละเอียดการสแกนต่ำสุดและสูงสุด

4.1.2.2 ผลการเปรียบเทียบผลลัพธ์ของสเปกตรัมที่มีต่อตำแหน่งการสแกนที่จุดแตกต่างกัน

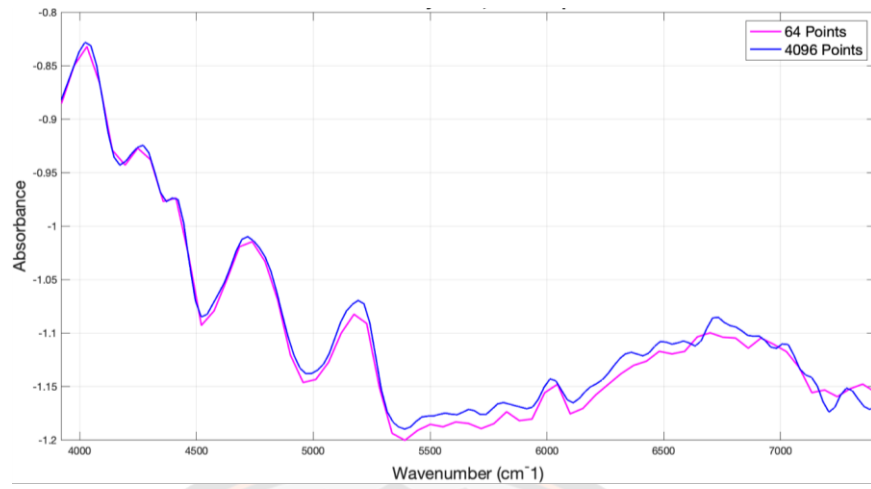
เมื่อทำการทดสอบเก็บข้อมูลสเปกตรัมจากตัวอย่างผ้าชนิดเดียวและสีเดียว ที่ตำแหน่งแตกต่างกัน 10 ตำแหน่ง พบว่า สเปกตรัมที่ได้จากแต่ละตำแหน่งการวัดมีการเบี่ยงเบนเล็กน้อยและมากขึ้นในช่วง 5,000 – 5,500 ดังภาพ 21 ซึ่งอาจแตกต่างกันไปในผ้าแต่ละชนิด ซึ่งโดยปกติในงานวิจัยด้านสเปกโตรสโคปีจะใช้วิธีการวัดข้อมูลสเปกตรัมด้วยค่าเฉลี่ยของการวัดซ้ำต่อตำแหน่ง ดังนั้นในงานวิจัยจึงใช้ข้อมูลสเปกตรัมแบบสแกนครั้งเดียวในตำแหน่งต่าง ๆ ที่มีความแปรปรวนแทนการหาค่าเฉลี่ยในการพัฒนาและสร้างแบบจำลองการจำแนก



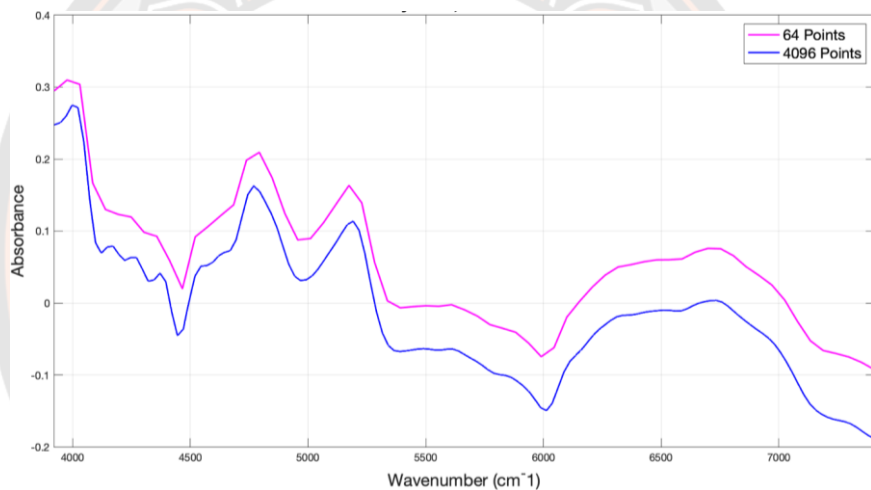
ภาพ 21 สเปกตรัมของผ้าตัวอย่างที่ ณ ตำแหน่งสแกน 10 ตำแหน่ง

4.1.2.3 ผลการเปรียบเทียบผลลัพธ์ของสเปกตรัมที่มีผลต่อวัสดุรองรับ

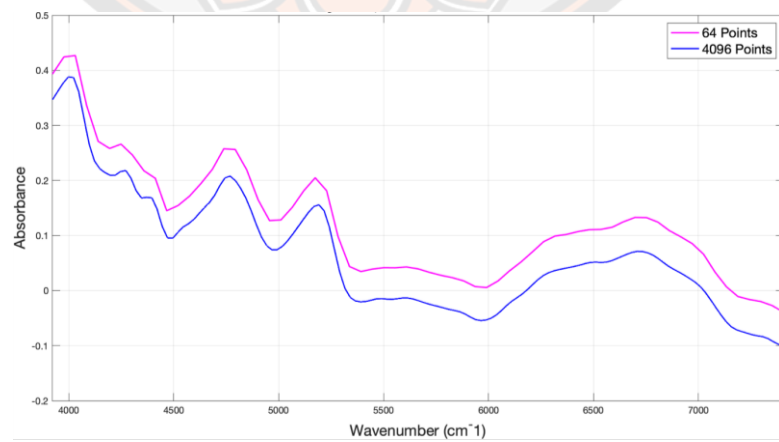
จากผลการทดสอบในภาพ 22 พบว่า สเปกตรัมที่สแกนบนแผ่นเพลต มีรูปร่างของสัญญาณแตกต่างจากสเปกตรัมที่สแกนบนโต๊ะรองรับหรือผ้าสะท้อนความร้อนอย่างชัดเจน แต่เมื่อเปรียบเทียบสัญญาณระหว่างโต๊ะรองรับกับผ้าสะท้อนความร้อน พบว่า รูปร่างของสัญญาณสเปกตรัมคล้ายกันแต่มีค่าดูดกลืนแสง (Absorbance) แตกต่างกันเล็กน้อยในแต่ละเลขคลื่น อาทิเช่น ที่เลขคลื่น 4,000 จะได้ค่า 0.3 และ 0.4 ตามลำดับ จึงทดสอบเก็บข้อมูลผ้าตัวอย่างทั้งหมดบนโต๊ะรองรับที่มีผ้าสะท้อนความร้อน เพื่อให้ได้ข้อมูลสเปกตรัมที่อยู่ในสภาพแวดล้อมใกล้เคียงกับการนำไปใช้งานจริง



(ก) สเปกตรัมผ้าตัวอย่างบนวัสดุแผ่นพลาสติก



(ข) สเปกตรัมผ้าตัวอย่างบนวัสดุใต้อะไรต์ผ้า




(ค) สเปกตรัมผ้าตัวอย่างบนวัสดุใต้อะไรต์ผ้าและผ้าสะท้อนความร้อน


ภาพ 22 เปรียบเทียบสเปกตรัมตัวอย่างผ้าบนพื้นผิววัสดุที่แตกต่างกัน

4.1.2.4. ผลการเปรียบเทียบผลลัพธ์ของสเปกตรัมที่มีผลต่อสีและกลุ่มเส้นใย


จากภาพ 23 แสดงตัวอย่างสเปกตรัมกลุ่มเส้นใยธรรมชาติจำนวน 2 ชนิด พบว่ารูปร่างของสัญญาณสเปกตรัมของตัวอย่างผ้าในกลุ่มเส้นใยเดียวกันจะมีรูปแบบสเปกตรัมคล้ายกัน โดยสังเกตจากค่าเฉลี่ยสเปกตรัม (เส้นสีแดง) แต่จะมีค่าการดูดกลืนแสงที่แตกต่างกันในแต่ละสีและแต่ละตัวอย่างยังคงมีการแปรปรวนไปจากการวัดในแต่ละครั้งหรือแต่ละตำแหน่ง และได้ผลลัพธ์เช่นกันเมื่อทำการเปรียบเทียบสเปกตรัมกลุ่มเส้นใยสังเคราะห์ จำนวน 2 ชนิด ดังภาพ 24




(ก) ผ้าตัวอย่างชนิดที่ 1 สีดำ



(ข) ผ้าตัวอย่างชนิดที่ 1 สีน้ำเงิน

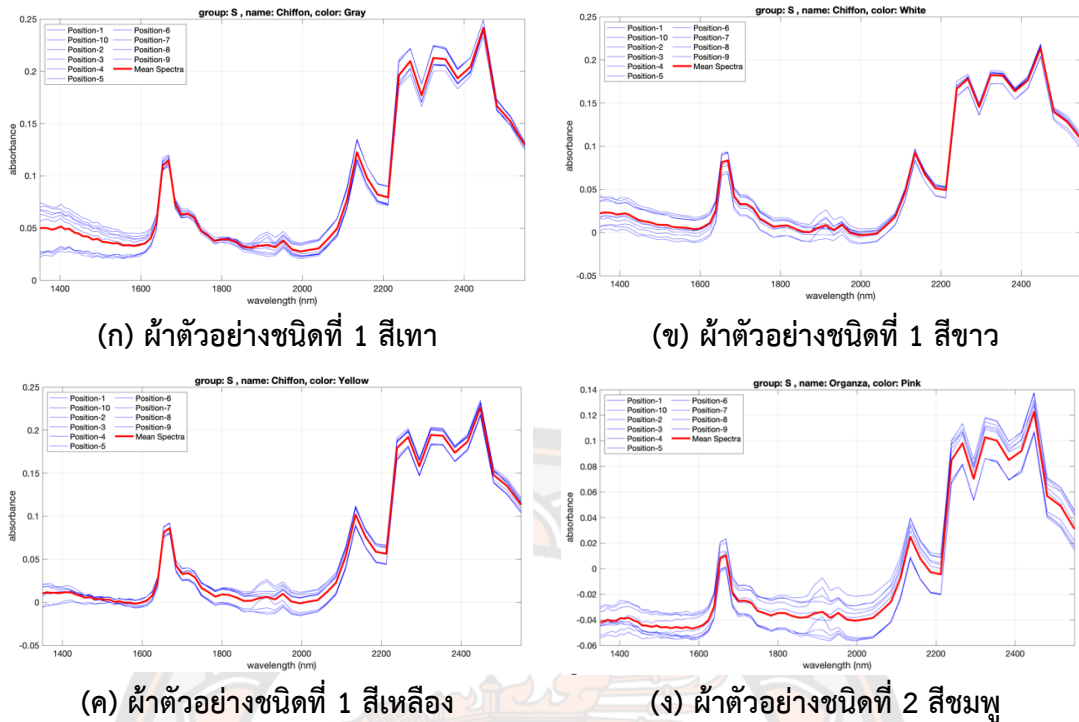


(ค) ผ้าตัวอย่างชนิดที่ 1 สีชมพู



(ง) ผ้าตัวอย่างชนิดที่ 2 สีเทา

ภาพ 23 สเปกตรัมของตัวอย่างผ้าในกลุ่มเส้นใยธรรมชาติที่มีสีและชนิดแตกต่างกัน



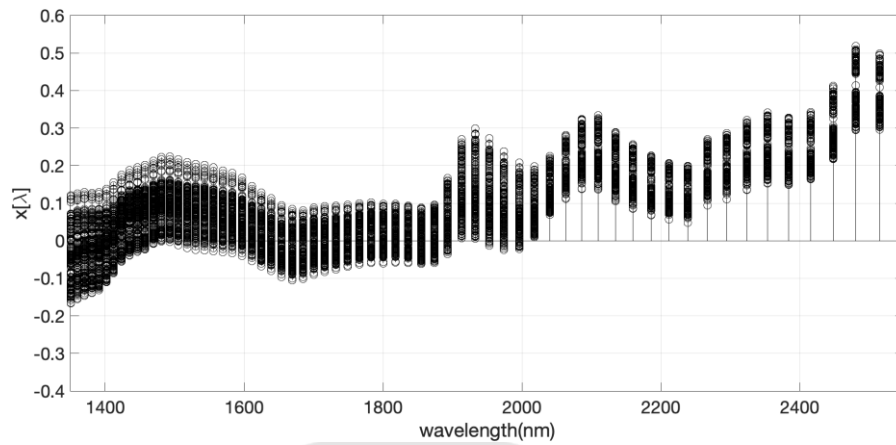
ภาพ 24 สเปกตรัมของตัวอย่างผ้าในกลุ่มเส้นใยสังเคราะห์ที่มีสีและชนิดแตกต่างกัน

4.1.3. ผลการพัฒนาอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใย


ขั้นตอนที่ 1: ผลการจัดเตรียมข้อมูล

ขั้นตอนที่ 1.1: ผลการเตรียมสัญญาณสเปกตรัมนำเข้า $\{x[\lambda_n]\}$


ทำการแปลงข้อมูลสัญญาณสเปกตรัมที่ได้จากการจัดเก็บข้อมูลสเปกตรัมบนวัสดุรองรับให้ อยู่ในรูปลำดับข้อมูล $\{x[\lambda_n]\}$ ของค่าดูดกลืนแสง (Absorbance) และความยาวคลื่น (λ_n) ที่อยู่ใน ย่านใกล้อินฟราเรดในช่วง 1350 ถึง 2500 นาโนเมตร โดยที่ $n \in \{0,1,2,3, \dots, 64\}$ เพื่อใช้แทนเป็น ลำดับข้อมูลสัญญาณสเปกตรัมนำเข้าใด ๆ ในการสร้างแบบจำลองการจำแนกของระบบจากตัวอย่าง ผ้าที่ใช้ในงานวิจัย 96 ผืนตั้งที่ระบุในตาราง 19 แต่เนื่องจากแต่ละตัวอย่างจะถูกทำการวัดสเปกตรัม ในตำแหน่งที่ต่างกันจำนวน 10 ตำแหน่งที่ให้มีสัญญาณนำเข้รวมทั้งหมด 960 สัญญาณ โดย แบ่งเป็นสัญญาณกลุ่มเส้นใยธรรมชาติจำนวน 210 สัญญาณ ดังภาพ 25 (ก) กลุ่มเส้นใยสังเคราะห์ จำนวน 480 สัญญาณ ดังภาพ 25 (ข) และกลุ่มเส้นใยผสมจำนวน 270 สัญญาณดังภาพ 25 (ค) ซึ่งใน แต่ละกลุ่มเส้นใยแสดงให้เห็นถึงความแปรปรวนของค่า $\{x[\lambda_n]\}$ ในทุก ๆ ตำแหน่ง λ_n ทำให้ยากต่อ การวิเคราะห์ข้อมูล และเลือกเฉพาะชุดของตำแหน่ง λ_n ที่สามารถใช้เป็นตัวแทนในการจำแนกกลุ่ม เส้นใยจากสัญญาณสเปกตรัมนำเข้าได้ จึงต้องมีขั้นตอนการนอร์มอลไลซ์สเปกตรัม เพื่อลดความ แปรปรวนและทำให้ลำดับพลังงานของสัญญาณเท่ากันก่อนนำไปเปรียบเทียบหรือวิเคราะห์



(ก) ลำดับข้อมูล $\{x[\lambda_n]\}$ ของกลุ่มเส้นใยธรรมดา



(ข) ลำดับข้อมูล $\{x[\lambda_n]\}$ ของกลุ่มเส้นใยสังเคราะห์



(ค) ลำดับข้อมูล $\{x[\lambda_n]\}$ ของกลุ่มเส้นใยผสม

ภาพ 25 ลำดับข้อมูลสเปกตรัมนำเข้าของตัวอย่างผ้าทดสอบทั้ง 3 กลุ่มเส้นใย

ขั้นตอนที่ 1.2: ผลการแบ่งชุดข้อมูลสำหรับชุดสอนและทดสอบแบบจำลอง

เพื่อทดสอบผลกระทบของจำนวนข้อมูลที่ใช้ในการสร้างแบบจำลองต่อประสิทธิภาพแบบจำลองการจำแนก จึงทำการแบ่งชุดข้อมูลสัญญาณสเปกตรัมในแต่ละกลุ่มเส้นใย สำหรับการสร้างและทดสอบแบบจำลองการจำแนกในอัตราส่วนที่แตกต่างกัน 3 อัตราส่วน คือ 60:40, 70:30 และ 80:20 โดยการแบ่งแต่ละอัตราส่วนจะทำการสุ่มสัญญาณสเปกตรัมให้ข้อมูลกระจายเท่า ๆ กันซ้ำจำนวน 10 รอบ ทำให้ได้จำนวนของข้อมูลสัญญาณสเปกตรัมในแต่ละอัตราส่วนดังแสดงในตาราง 14 และจะใช้ข้อมูลข้อมูลสัญญาณสเปกตรัมเฉพาะในส่วนของชุดสอนในการดำเนินการสร้างแบบจำลองการจำแนกสิ่งทอตามชนิดของเส้นใยในขั้นตอนต่อไป

ตาราง 14 จำนวนข้อมูลสัญญาณสเปกตรัมสำหรับชุดสอนและทดสอบแบบจำลอง

อัตราส่วน	จำนวนชุดสอนแบบจำลอง			จำนวนชุดทดสอบแบบจำลอง		
	กลุ่มเส้นใย	กลุ่มเส้นใย	กลุ่มเส้นใย	กลุ่มเส้นใย	กลุ่มเส้นใย	กลุ่มเส้นใย
ชุดสอนและ ทดสอบ	ธรรมชาติ	สังเคราะห์	ผสม	ธรรมชาติ	สังเคราะห์	ผสม
60:40	126	288	162	84	192	108
70:30	147	336	189	63	144	81
80:20	168	384	216	42	96	54


ขั้นตอนที่ 2: ผลการสกัดเวกเตอร์คุณลักษณะใหม่

ขั้นตอนที่ 2.1 ผลการสร้างสัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัมของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์


เพื่อลดความแปรปรวนและทำให้ลำดับพลังงานของสัญญาณเท่ากันก่อนนำไปเปรียบเทียบหรือวิเคราะห์ จึงนำสัญญาณนำเข้า $\{x[\lambda_n]\}$ ในแต่ละกลุ่มเส้นใยไปนอร์มอลไลซ์สเปกตรัมด้วยวิธีการที่นำเสนอในงานวิจัย (Yammen & Limsripraphan, 2022) ซึ่งแสดงให้เห็นว่ามีผลทำให้แบบจำลองการจำแนกมีความแม่นยำมากขึ้น โดยผลลัพธ์ของสัญญาณหลังการทำ นอร์มอลไลซ์จะมีค่าเฉลี่ยของสัญญาณเท่ากับศูนย์ และค่าพลังงานของสัญญาณรวมของสัญญาณเท่ากับหนึ่ง ทำให้ได้สัญญาณนอร์มอลไลซ์สเปกตรัม $\{x[n]\}$ ของแต่ละกลุ่มเส้นใยดังภาพ 26 (ก-ค)

ซึ่งเมื่อเปรียบเทียบสัญญาณนอร์มอลไลซ์สเปกตรัม $\{x[n]\}$ ระหว่างกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ ในภาพ 26 (ก) และ 26 (ข) พบว่า มีค่า $x[n]$ ที่ให้ค่าแตกต่างกันอย่างชัดเจน เช่น ตำแหน่ง n ที่ 26 และ 27 (ลูกศรสีแดง) ของกลุ่มเส้นใยธรรมชาติ มีค่าน้อยกว่าศูนย์แต่กลุ่มเส้นใยสังเคราะห์จะมีค่ามากกว่าศูนย์ แต่ยังไม่สามารถนำมาใช้ใน การจำแนกความแตกต่างของ


กลุ่มเส้นใยผสมได้ เนื่องจากสัญญาณของกลุ่มเส้นใยผสมมีลักษณะของรูปแบบสัญญาณร่วมกัน ระหว่างกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ดังแสดงในภาพ 26 (ค)



(ก) นอร์มอลไลซ์สเปกตรัมกลุ่มเส้นใยธรรมชาติ



(ข) นอร์มอลไลซ์สเปกตรัมกลุ่มเส้นใยสังเคราะห์




(ค) นอร์มอลไลซ์สเปกตรัมกลุ่มเส้นใยผสม


ภาพ 26 นอร์มอลไลซ์สเปกตรัมของตัวอย่างผ้าทดสอบทั้ง 3 กลุ่ม

ดังนั้น คณะวิจัยจึงต้องการสร้างสัญญาณตัวแทนของกลุ่มเส้นใยธรรมชาติ $\{r_n[n]\}$ และกลุ่มเส้นใยสังเคราะห์ $\{r_s[n]\}$ เพื่อใช้ในการนำไปตรวจสอบกับสัญญาณนำเข้าใด ๆ ในรูปแบบระยะห่างระหว่างสองเวกเตอร์ด้วยวิธีการที่นำเสนอในขั้นตอนต่อไป โดยใช้เฉพาะข้อมูลสัญญาณสเปกตรัมจากกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ที่ผ่านการลดความแปรปรวนด้วย การลบด้วยค่าเฉลี่ยของตัวสัญญาณ แล้วนำมาหาค่าเฉลี่ยสัญญาณของแต่ละกลุ่มและ ทำนอร์มอลไลซ์สเปกตรัม


ด้วยการหารด้วยแอลทูนอร์มของตัวสัญญาณ ทำให้ได้สัญญาณตัวแทน กลุ่มเส้นใยธรรมชาติ $\{r_n[n]\}$ ดังภาพ 27 (ก-ค) และสัญญาณตัวแทนกลุ่มเส้นใยสังเคราะห์ $\{r_s[n]\}$ ดังภาพ 27 (ง-ฉ) ของทุกอัตราส่วนของชุดข้อมูลสอน จากภาพแสดงให้เห็นว่า พบว่า อัตราส่วนของชุดข้อมูลสอนมีผลกระทบต่อการสร้างสัญญาณตัวแทนของกลุ่มน้อยมาก โดยมีค่าเบี่ยงเบนมาตรฐานเฉลี่ยของทุกอัตราส่วนอยู่ที่ 0.0004 และ 0.0002 สำหรับกลุ่มเส้นใยธรรมชาติและ กลุ่มเส้นใยสังเคราะห์ตามลำดับ



(ก) สัญญาณตัวแทนกลุ่มเส้นใยธรรมชาติอัตราส่วน ชุดข้อมูลสอนและทดสอบ 60:40 (ง) สัญญาณตัวแทนกลุ่มเส้นใยสังเคราะห์อัตราส่วน ชุดข้อมูลสอนและทดสอบ 60:40



(ข) สัญญาณตัวแทนกลุ่มเส้นใยธรรมชาติอัตราส่วน ชุดข้อมูลสอนและทดสอบ 70:30 (จ) สัญญาณตัวแทนกลุ่มเส้นใยสังเคราะห์อัตราส่วน ชุดข้อมูลสอนและทดสอบ 70:30



(ค) สัญญาณตัวแทนกลุ่มเส้นใยธรรมชาติอัตราส่วน ชุดข้อมูลสอนและทดสอบ 80:20 (ฉ) สัญญาณตัวแทนกลุ่มเส้นใยสังเคราะห์อัตราส่วน ชุดข้อมูลสอนและทดสอบ 80:20


ภาพ 27 สัญญาณตัวแทนกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์

ขั้นตอนที่ 2.2 : ผลการวิเคราะห์สัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัมในโดเมนความถี่


ขั้นตอนที่ 2.2.1: ผลการแปลงสัญญาณตัวแทนกลุ่มให้อยู่ในรูปส่วนจริงของโดเมนความถี่

เพื่อให้สอดคล้องประเด็นปัญหาของงานวิจัยที่ต้องลดจำนวนข้อมูลสัญญาณสเปกตรัม แต่ยังบอกได้ถึงคุณลักษณะเด่นของสัญญาณสเปกตรัมแต่ละกลุ่มเส้นใย คณะผู้วิจัยจึงนำเสนอการแปลง


สัญญาณสเปกตรัมให้อยู่ในโดเมนความถี่ โดยแปลงให้อยู่ในรูปส่วนจริงของ อนุกรมฟูเรียร์ของลำดับคาบ (DFT: Discrete Fourier Transform) ซึ่งผู้วิจัยของเรียกการแปลงนี้ว่า RDFT (Real part of Discrete Fourier Transform) เพื่อช่วยให้การวิเคราะห์สัญญาณในโดเมนความถี่และเข้าใจคุณสมบัติต่าง ๆ ของสัญญาณมากขึ้น ทำให้ได้สัญญาณตัวแทนของกลุ่มเส้นใยธรรมชาติ $\{r_n[n]\}$ และกลุ่มเส้นใยสังเคราะห์ $\{r_s[n]\}$ หลังการแปลง RDFT เป็นลำดับสัญญาณ $\{ReR_n[n]\}$ และลำดับสัญญาณ $\{ReR_s[n]\}$ ตามลำดับของทุกอัตราส่วนของชุดข้อมูลสอน ดังภาพ 28




(ก) สัญญาณ RDFT กลุ่มเส้นใยธรรมชาติ อัตราส่วนชุดข้อมูลสอนและทดสอบ 60:40




(ง) สัญญาณ RDFT กลุ่มเส้นใยสังเคราะห์ อัตราส่วนชุดข้อมูลสอนและทดสอบ 60:40




(ข) สัญญาณ RDFT กลุ่มเส้นใยธรรมชาติ อัตราส่วนชุดข้อมูลสอนและทดสอบ 70:30



(จ) สัญญาณ RDFT กลุ่มเส้นใยสังเคราะห์ อัตราส่วนชุดข้อมูลสอนและทดสอบ 70:30



(ค) สัญญาณ RDFT กลุ่มเส้นใยธรรมชาติ อัตราส่วนชุดข้อมูลสอนและทดสอบ 80:20




(ฉ) สัญญาณ RDFT กลุ่มเส้นใยสังเคราะห์ อัตราส่วนชุดข้อมูลสอนและทดสอบ 80:20

ภาพ 28 ลำดับสัญญาณ RDFT ของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์

ขั้นตอนที่ 2.2.2 ผลการเปรียบเทียบหาตำแหน่งความถี่ k ที่ใช้สร้างเวกเตอร์ตัวแทนคุณลักษณะ จากภาพ 29 พบว่า ค่าลำดับสัญญาณ RDFT ณ ตำแหน่งดัชนีความถี่ที่ $k \in \{1, 2, 3 \dots 32\}$ สอดคล้องกับค่าลำดับสัญญาณ RDFT ณ ตำแหน่งที่ $k \in \{33, 34, 35 \dots 64\}$ ซึ่งเป็นไปตามคุณสมบัติของอนุกรมฟูเรียร์ของลำดับคาบในกรณีที่มี N เป็นเลขคี่ จึงเลือกใช้เฉพาะลำดับสัญญาณ $\{ReR_n[n]\}$ และลำดับสัญญาณ $\{ReR_s[n]\}$ ในการเปรียบเทียบเพื่อหาตำแหน่งดัชนีความถี่ k ที่สามารถใช้เป็นตัวแทนในการจำแนกสัญญาณระหว่างกลุ่มเส้นใยอย่างมีนัยสำคัญ โดยทำการหา

เฉพาะตำแหน่ง k ที่มีค่าเครื่องหมายแตกต่างกัน พบว่า มีตำแหน่งที่มีค่าเครื่องหมายแตกต่างกันจำนวน 8 ตำแหน่ง ดังภาพ 29 และเมื่อพิจารณาเฉพาะตำแหน่งความถี่ k ที่มีค่าความแตกต่างของค่า (Δ_k) มากกว่าค่าที่ผู้วิจัยเลือกใช้ ค่า -3dB หรือ $\frac{1}{\sqrt{2}}$ ทำให้เหลือตำแหน่งความถี่ k เพียง 4 ตำแหน่ง คือ ตำแหน่งที่ 2, 3, 4 และ 13 ซึ่งเมื่อนำไปทดสอบทำซ้ำ โดยใช้ชุดข้อมูลจากทุกอัตราส่วนชุดข้อมูลสอนและชุดทดสอบ ทำให้ได้ผลลัพธ์ของตำแหน่งความถี่และค่าความต่างดังแสดงในตาราง 15 ถึงตาราง 17



ภาพ 29 เปรียบเทียบลำดับสัญญาณ RDFT กลุ่มเส้นใยธรรมชาติและเส้นใยสังเคราะห์

ตาราง 15 ข้อมูลความถี่ที่ใช้สร้างเวกเตอร์คุณลักษณะของชุดข้อมูลสอนและทดสอบ 60:40

รอบการทำซ้ำ	ค่าความแตกต่าง Δ_k			
	$k = 2$	$k = 3$	$k = 4$	$k = 13$
1	1.9910	1.1352	1.4735	0.8231
2	1.9823	1.1186	1.4938	0.8258
3	1.9759	1.1086	1.5007	0.8268
4	1.9834	1.1262	1.4877	0.8250
5	1.9751	1.1064	1.5061	0.8262
6	1.9815	1.1136	1.4994	0.8277
7	1.9782	1.1358	1.4789	0.8221
8	1.9785	1.1357	1.4812	0.8233
9	1.9776	1.1280	1.4897	0.8249
10	1.9815	1.1201	1.4946	0.8264
ค่าเฉลี่ย	1.9805	1.1228	1.4906	0.8251
ค่าเบี่ยงเบน	0.0046	0.0111	0.0104	0.0018

ตาราง 16 ข้อมูลความถี่ที่ใช้สร้างเวกเตอร์คุณลักษณะของชุดข้อมูลสอนและทดสอบ 70:30

รอบการทำซ้ำ	ค่าความแตกต่าง Δ_k			
	$k = 2$	$k = 3$	$k = 2$	$k = 13$
1	1.9815	1.1159	1.4948	0.8266
2	1.9792	1.1196	1.4942	0.8259
3	1.9793	1.1249	1.4899	0.8249
4	1.9863	1.1141	1.4995	0.8285
5	1.9820	1.1192	1.4942	0.8265
6	1.9883	1.1348	1.4806	0.8242
7	1.9760	1.1173	1.4955	0.8258
8	1.9823	1.1224	1.4935	0.8265
9	1.9841	1.1335	1.4795	0.8239
10	1.9827	1.1084	1.4994	0.8276
ค่าเฉลี่ย	1.9822	1.1210	1.4921	0.8260
ค่าเบี่ยงเบน	0.0036	0.0083	0.0069	0.0014

ตาราง 17 ข้อมูลความถี่ที่ใช้สร้างเวกเตอร์คุณลักษณะของชุดข้อมูลสอนและทดสอบ 80:20

รอบการทำซ้ำ	ค่าความแตกต่าง Δ_k			
	$k = 2$	$k = 3$	$k = 2$	$k = 13$
1	1.9863	1.1172	1.4936	0.8271
2	1.9856	1.1203	1.4927	0.8269
3	1.9817	1.1200	1.4912	0.8261
4	1.9795	1.1233	1.4883	0.8241
5	1.9812	1.1162	1.4943	0.8265
6	1.9827	1.1251	1.4879	0.8252
7	1.9750	1.1168	1.4969	0.8260
8	1.9835	1.1275	1.4854	0.8248
9	1.9780	1.1174	1.4961	0.8262
10	1.9872	1.1245	1.4910	0.8269
ค่าเฉลี่ย	1.9821	1.1208	1.4917	0.8260
ค่าเบี่ยงเบน	0.0038	0.0040	0.0037	0.0010

จากตาราง 15 ถึงตาราง 17 พบว่า ทุกอัตราส่วนชุดข้อมูลสอนและทดสอบที่มีการสุ่มข้อมูล เพื่อแบ่งชุดข้อมูลจำนวน 10 ครั้ง จะได้ตำแหน่งดัชนีความถี่ k ที่มีความแตกต่างกันของเครื่องหมาย และค่าความต่างของลำดับสัญญาณ $\{ReR_n[n]\}$ และ $\{ReR_s[n]\}$ มากกว่า -3dB อย่างคงที่ คือ พบที่ตำแหน่ง 2, 3, 4 และ 13 ในทุกครั้งของรอบการทดสอบซ้ำสำหรับทุกอัตราส่วน โดยมีค่าเฉลี่ย ค่าความแตกต่างของทั้ง 4 ตำแหน่งเท่ากับ 1.9805 ± 0.0046 , 1.1228 ± 0.0111 , 1.4906 ± 0.0104 และ 0.8251 ± 0.0018 ตามลำดับ สำหรับอัตราส่วนชุดข้อมูล 60:40 และมีค่าเท่ากับ 1.9822 ± 0.0036 , 1.1210 ± 0.0083 , 1.4921 ± 0.0069 และ 0.8260 ± 0.0014 ตามลำดับ สำหรับอัตราส่วนชุดข้อมูล 70:30 และสำหรับอัตราส่วนชุดข้อมูล 80:20 ได้ค่าเท่ากับ 1.9821 ± 0.0038 , 1.1208 ± 0.0040 , 1.4917 ± 0.0037 และ 0.8260 ± 0.0010 ตามลำดับ จากข้อมูลพบว่า ในแต่ละรอบการทดสอบซ้ำหรือ ในแต่ละอัตราส่วนที่เปลี่ยนแปลงไปมีค่าเบี่ยงเบนมาตรฐานของค่าความต่างที่ต่ำมาก ซึ่งแสดงให้เห็นว่า ตำแหน่งความถี่ที่เลือกทั้ง 4 ตำแหน่งมีความแตกต่างกันอย่างมีนัยสำคัญ จึงใช้ทั้ง 4 ตำแหน่งนี้กำหนด เป็นสมาชิกของเซตดัชนีความถี่ \mathcal{K} ที่จัดเก็บตำแหน่งดัชนีความถี่ที่จะใช้ในการสร้างเวกเตอร์ตัวแทน คุณลักษณะและเวกเตอร์สัญญาณนำเข้าใดๆ สำหรับการสร้างแบบจำลองการจำแนกสิ่งทอตามชนิด ของเส้นใยในขั้นตอนต่อไป

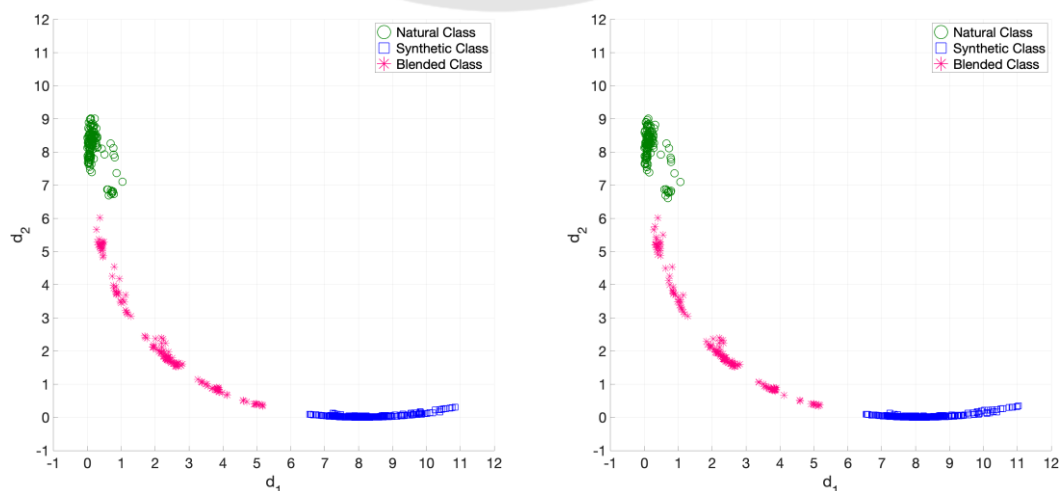
ขั้นตอนที่ 2.2.3. ผลการสร้างเวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์

ใช้สัญญาณค่าลำดับข้อมูลของสัญญาณ $\{ReR_n[k]\}$ และ $\{ReR_s[k]\}$ ที่ได้จากขั้นตอนที่ 2.2.2 ซึ่งเป็นสัญญาณตัวแทนกลุ่มที่ถูกแปลงอยู่ในโดเมนความถี่ของการแปลง DFT และเลือกใช้และใช้เฉพาะส่วนจริง ณ ตำแหน่งดัชนีความถี่ที่อยู่ในเซต \mathcal{K} ทำให้ได้เวกเตอร์ตัวแทนคุณลักษณะของสัญญาณในกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ โดยแทนด้วยเวกเตอร์ \underline{f}_n , \underline{f}_s ตามลำดับดังสมการที่ 4-2


$$\underline{f}_n = \begin{bmatrix} ReR_n[2] \\ ReR_n[3] \\ ReR_n[4] \\ ReR_n[13] \end{bmatrix}_{4 \times 1}, \underline{f}_s = \begin{bmatrix} ReR_s[2] \\ ReR_s[3] \\ ReR_s[4] \\ ReR_s[13] \end{bmatrix}_{4 \times 1}, \underline{f}_x = \begin{bmatrix} ReX[2] \\ ReX[3] \\ ReX[4] \\ ReX[13] \end{bmatrix}_{4 \times 1} \quad (4-2)$$

ขั้นตอนที่ 2.2.4. ผลสร้างเวกเตอร์คุณลักษณะใหม่


สร้างเวกเตอร์นำเข้าใด ๆ \underline{f}_x จากสัญญาณ $\{x[n]\}$ ที่ผ่านการนอร์มอลไลซ์สเปกตรัมเพื่อลดความแปรปรวนของสัญญาณและทำให้ลำดับของพลังงานรวมเท่ากับสัญญาณตัวแทนกลุ่มก่อนนำไปสร้างเวกเตอร์คุณลักษณะใหม่ด้วยวิธีการที่ผู้วิจัยนำเสนอ คือ แปลงสัญญาณ นอร์มอลไลซ์สเปกตรัมให้อยู่ในรูปส่วนจริงของโดเมนความถี่ (RDFT) และเลือกเฉพาะดัชนีเซตตำแหน่งความถี่ \mathcal{K} เช่นเดียวกับขั้นตอนการสร้างเวกเตอร์ตัวแทนกลุ่ม เพื่อนำไปสร้างเวกเตอร์คุณลักษณะใหม่ \underline{d} ซึ่งจะแสดงถึงระยะห่างระหว่างเวกเตอร์นำเข้าใด ๆ กับเวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและเวกเตอร์ตัวแทนกลุ่มเส้นใยสังเคราะห์ด้วยวิธีแอลทูนอร์ม ทำให้ได้เวกเตอร์คุณลักษณะใหม่ ที่สามารถแสดงการกระจายตัวของข้อมูลจากแต่ละกลุ่มเส้นใยของทุกอัตราส่วนชุดข้อมูลสอนดังภาพ 30 - 32




(ก) รอบการสุ่มที่ 1




(ข) รอบการสุ่มที่ 2




(ค) รอบการสุ่มที่ 3




(ง) รอบการสุ่มที่ 4



(จ) รอบการสุ่มที่ 5




(ฉ) รอบการสุ่มที่ 6




(ช) รอบการสุ่มที่ 7

(ซ) รอบการสุ่มที่ 8




(ฉ) รอบการสุ่มที่ 9




(ญ) รอบการสุ่มที่ 10


ภาพ 30 การจำแนกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 60:40




(ก) รอบการสุ่มที่ 1




(ข) รอบการสุ่มที่ 2




(ค) รอบการสุ่มที่ 3




(ง) รอบการสุ่มที่ 4



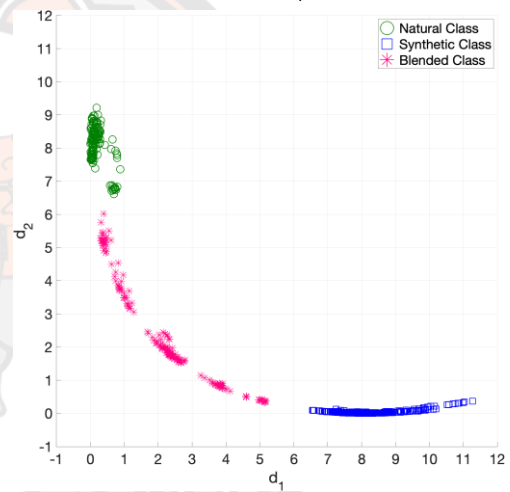
(จ) รอบการสุ่มที่ 5




(ฉ) รอบการสุ่มที่ 6




(ช) รอบการสุ่มที่ 7



(ซ) รอบการสุ่มที่ 8




(ณ) รอบการสุ่มที่ 9




(ญ) รอบการสุ่มที่ 10


ภาพ 31 การจำแนกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 70:30



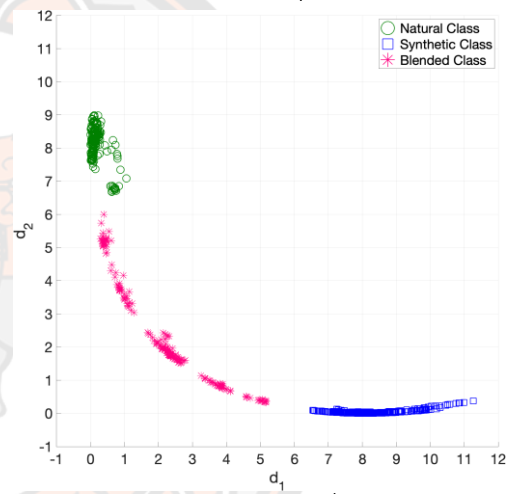
(ก) รอบการสุ่มที่ 1




(ข) รอบการสุ่มที่ 2




(ค) รอบการสุ่มที่ 3



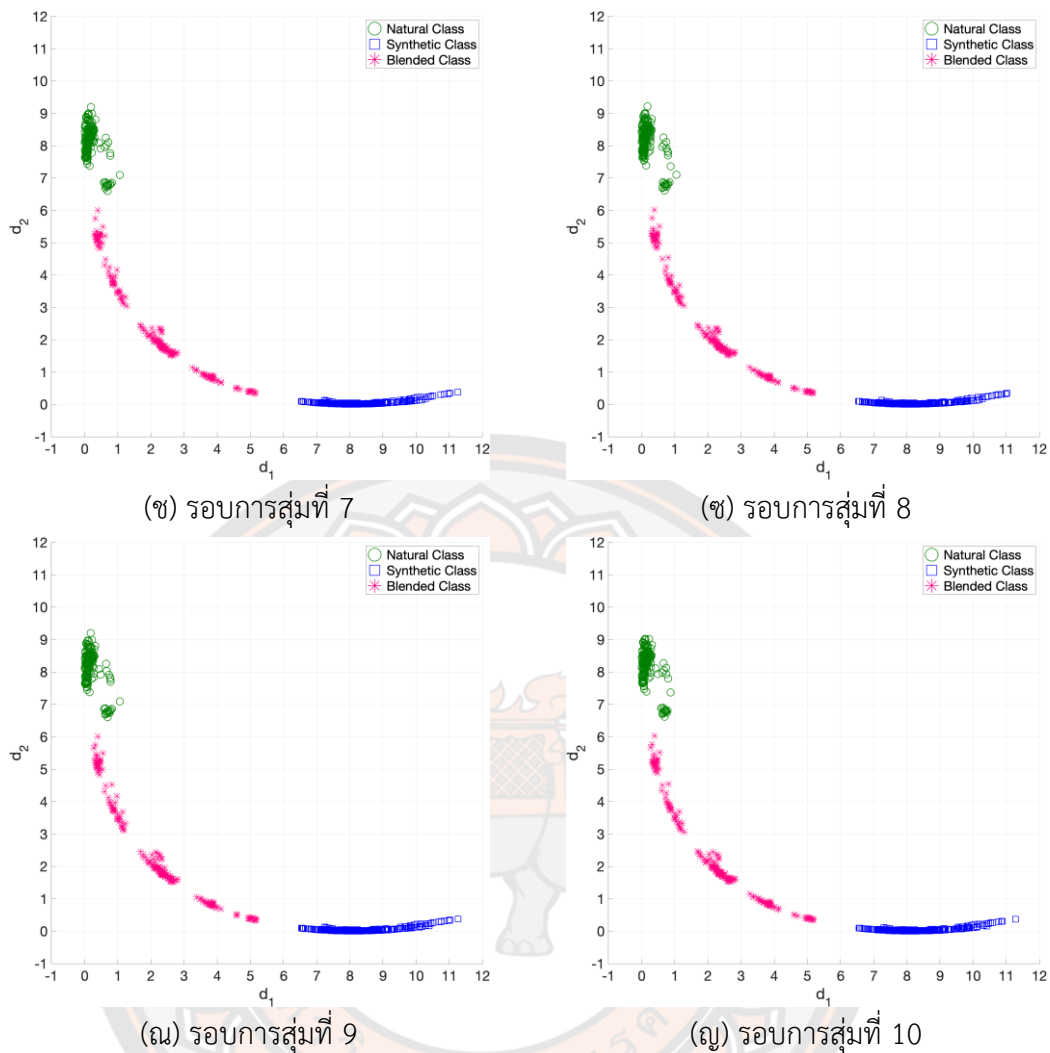
(ง) รอบการสุ่มที่ 4



(จ) รอบการสุ่มที่ 5



(ฉ) รอบการสุ่มที่ 6



ภาพ 32 การจำแนกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 80:20

จากภาพ 30 ถึง 32 แสดงให้เห็นว่า เวกเตอร์คุณลักษณะใหม่ d ที่ผู้วิจัยนำเสนอ มีการแบ่งแยกชุดข้อมูลของแต่ละกลุ่มเส้นใยออกจากกันอย่างชัดเจนในทุกกรอบการทดสอบซ้ำและทุกอัตราส่วนของชุดข้อมูลสอนและชุดข้อมูลทดสอบ นอกจากนี้ข้อมูลระหว่างกลุ่มเส้นใยยังมีลักษณะที่สามารถแบ่งได้ด้วยการแบ่งเชิงเส้น จึงทำให้ผู้วิจัยเสนอการใช้แบ่งข้อมูลโดยใช้วิธีการซัพพอร์ตเวกเตอร์แมชชีนแบบเชิงเส้นดังผลลัพธ์ที่แสดงในขั้นตอนที่ 3

ขั้นตอนที่ 3: ผลการสร้างแบบจำลองการจำแนกด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีน

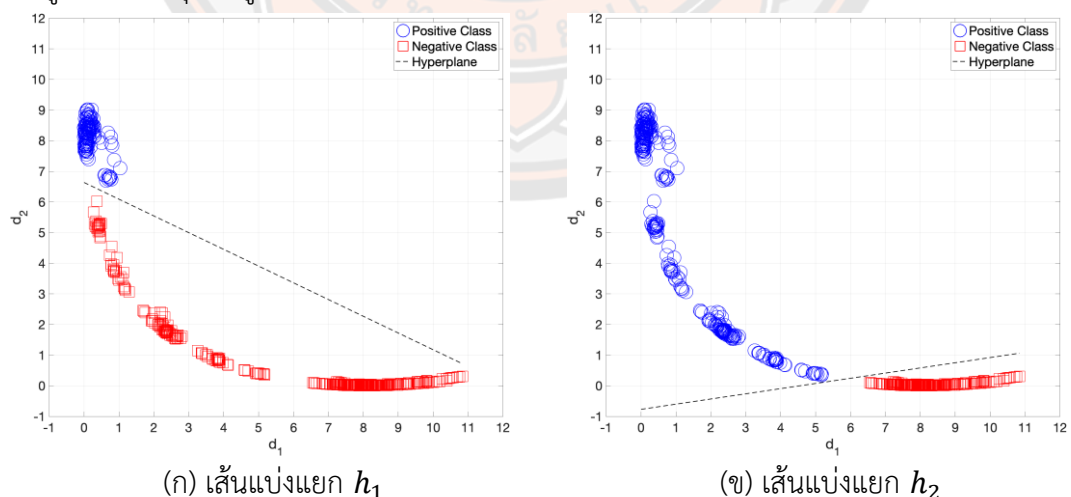
ในงานวิจัยนี้ต้องการจำแนกประเภทสิ่งทอออกเป็น 3 กลุ่ม คือ กลุ่มเส้นใยธรรมชาติ กลุ่มเส้นใยสังเคราะห์ และกลุ่มเส้นใยผสม ผู้วิจัยจึงต้องการใช้ซัพพอร์ตเวกเตอร์แมชชีนแบบจำแนกมากกว่าสองกลุ่ม (Multiclass Classification) ซึ่งโดยปกติจะใช้วิธีการคัดแยกทีละหนึ่งต่อหนึ่ง (One-against-

One) ทำให้มีจำเป็นต้องฟังก์ชันของสมการเส้นแบ่งจำนวน 3 สมการดังกล่าวไว้ในบทที่ 3 ผู้วิจัยจึงนำเสนอการสร้างสมการเส้นแบ่งแยก (Hyperplane) ที่ลดจำนวนการคำนวณโดยใช้เพียง 2 สมการ คือ สมการเส้นแบ่งแยกที่หนึ่ง $h_1(\underline{d})$ โดยใช้ชุดข้อมูลจากกลุ่มเส้นใยธรรมชาติเป็น Positive Class (+1) และชุดข้อมูลจากกลุ่มเส้นใยผสมและกลุ่มเส้นใยสังเคราะห์เป็น Negative Class (-1) ส่วนสมการเส้นแบ่งแยกที่สอง $h_2(\underline{d})$ โดยใช้ชุดข้อมูลจากกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยผสมเป็น Positive Class (+1) และชุดข้อมูลจากกลุ่มเส้นใยสังเคราะห์เป็น Negative Class (-1) ทำให้ผลลัพธ์ดังตาราง 18

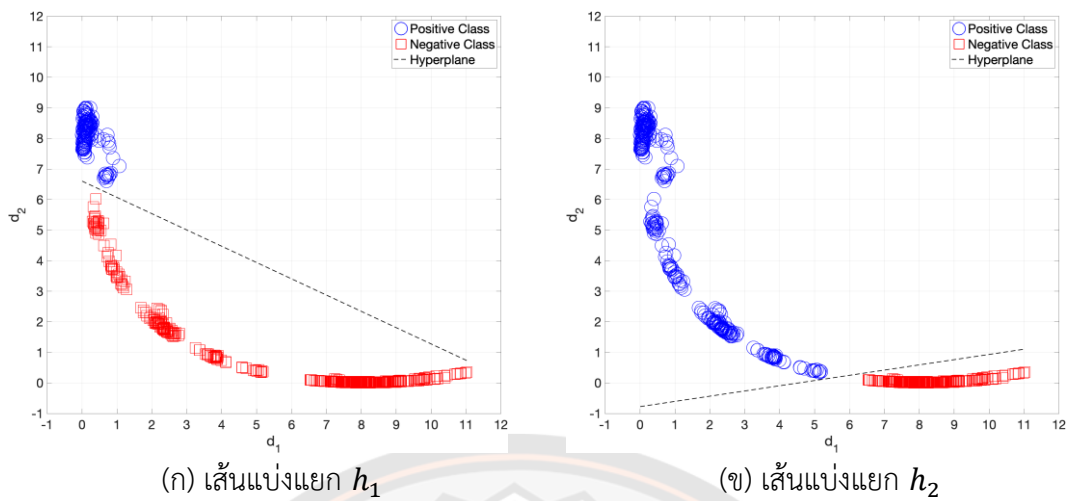
ตาราง 18 สมการเส้นแบ่งแยกสำหรับจำแนกประเภทสิ่งทอออกเป็น 3 กลุ่ม

$y_i = 1$	$y_i = -1$	สมการเส้นแบ่ง
กลุ่มเส้นใยธรรมชาติ	กลุ่มเส้นใยสังเคราะห์ และกลุ่มเส้นใยผสม	$h_1(\underline{d}) = w_1^T \underline{d} + b_1$
กลุ่มเส้นใยธรรมชาติ และกลุ่มเส้นใยผสม	กลุ่มเส้นใยสังเคราะห์	$h_2(\underline{d}) = w_2^T \underline{d} + b_2$

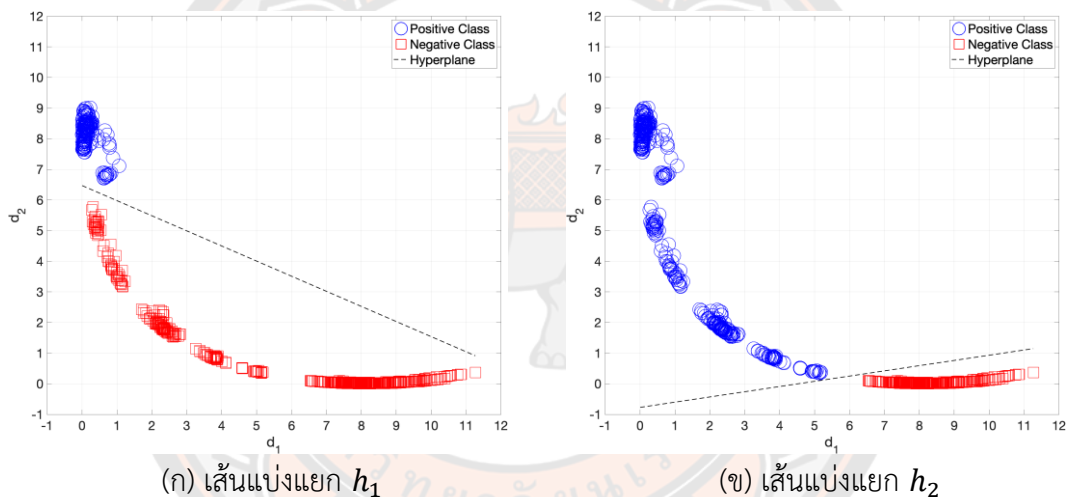
เมื่อใช้การจัดแบ่งกลุ่มข้อมูล Positive Class (+1) และ Negative Class (-1) ตามที่กำหนดในตาราง 25 ทำให้ได้แสดงเส้นแบ่งแยก h_1 และ h_2 สำหรับใช้ทดสอบในแต่ละอัตราส่วนชุดข้อมูลสอนและชุดข้อมูลทดสอบ 60:40, 70:30 และ 80:20 ตามลำดับ ดังแสดงในภาพ 33 ถึง 35



ภาพ 33 สมการเส้นแบ่งแยกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 60:40



ภาพ 34 สมการเส้นแบ่งแยกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 70:30



ภาพ 35 สมการเส้นแบ่งแยกข้อมูลคุณลักษณะใหม่ของชุดข้อมูลสอนอัตราส่วน 80:20

จากผลลัพธ์ของการสร้างแบบจำลองด้วยซัพพอร์ตเวกเตอร์แมชชีนแบบจำแนกมากกว่าสองกลุ่มด้วยวิธีการที่นำเสนอใช้ 2 สมการเส้นแบ่งแยกในภาพที่ 33 - 35 พบว่า ในทุกอัตราส่วนชุดข้อมูลสอนและชุดข้อมูลทดสอบ สามารถแบ่งแยกกลุ่ม Positive Class และ Negative Class ได้อย่างชัดเจนด้วยสมการเส้นแบ่งแยกที่เหมาะสมที่สุด จึงทำการทดสอบซ้ำในแต่ละอัตราส่วนด้วยการสุ่มแบ่งชุดข้อมูลจำนวน 10 รอบ ทำให้ได้ค่าเวกเตอร์ \vec{w} และค่า b ของทั้งสองสมการ เส้นแบ่งแยกดังแสดงตาราง 19 ที่แสดงให้เห็นว่า เวกเตอร์ \vec{w} ของสมการเส้นแบ่งแยกหนึ่ง มีค่าเบี่ยงเบนมาตรฐานมากกว่าของสมการเส้นแบ่งแยกสองที่ 0.2154, 0.3529 กับ 0.0044, 0.0485 ตามลำดับ และมีค่า b มีค่าเบี่ยงเบนมาตรฐานที่แตกต่างกันอย่างชัดเจนที่ 2.4825 กับ 0.0231 ทำให้สามารถสรุปได้ว่าสมการเส้นแบ่งแยกที่หนึ่งมีการเปลี่ยนแปลงไปตามชุดข้อมูลที่ทำการสุ่ม ซึ่งอาจเกิดจากชุดข้อมูลของกลุ่มเส้นใย

ธรรมชาติที่ถูกระบุเป็น Positive Class มีการแปรปรวนและกระจายตัวทำให้สมการเส้นแบ่งแยกหนึ่งมีค่าเบี่ยงเบนมาตรฐานที่สูงกว่าสมการเส้นแบ่งแยกที่สอง โดยสังเกตในรอบการทำซ้ำที่ 4, 7 และ 8 ได้จากค่า b_1 ที่มีค่าเท่ากับ -12.3372, -11.8537 และ -12.3006 และค่าเวกเตอร์ \bar{w} ที่มีค่าเท่ากับ (0.9413, 1.9181), (0.9026, 1.8405) และ (0.9706, 1.9161) ตามลำดับ

ตาราง 19 เวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกสำหรับชุดข้อมูลอัตราส่วน 60:40

รอบการทำซ้ำ	$h_1(d)$		$h_2(d)$			
	\bar{w}_1	b_1	\bar{w}_2	b_2		
1	1.3346	2.4443	-16.2197	-0.7009	4.1469	3.1958
2	1.4131	2.6507	-17.5062	-0.7007	4.1046	3.1857
3	1.2889	2.4824	-16.4322	-0.7102	4.2033	3.2327
4	0.9413	1.9181	-12.3372	-0.6994	4.1587	3.1968
5	1.4119	2.6550	-17.5135	-0.7077	4.2106	3.2287
6	1.3934	2.6776	-17.6884	-0.7009	4.1645	3.1886
7	0.9026	1.8405	-11.8537	-0.6999	4.0751	3.2044
8	0.9706	1.9161	-12.3006	-0.7069	4.1545	3.2488
9	1.4083	2.6466	-17.4507	-0.7062	4.1856	3.2207
10	1.3799	2.6612	-17.5527	-0.6968	4.0759	3.1805
ค่าเฉลี่ย	1.2444	2.3892	-15.6855	-0.7030	4.1480	3.2083
ค่าเบี่ยงเบนมาตรฐาน	0.2154	0.3529	2.4825*	0.0044	0.0485	0.0231

ตาราง 20 เวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกสำหรับชุดข้อมูลอัตราส่วน 70:30

รอบการทำซ้ำ	$h_1(\underline{d})$		$h_2(\underline{d})$			
	\bar{w}_1	b_1	\bar{w}_2	b_2		
1	1.4080	2.6425	-17.4485	-0.7011	4.1059	3.1879
2	1.2979	2.5076	-16.5718	-0.7018	4.1083	3.2010
3	1.3885	2.6714	-17.6187	-0.7030	4.1521	3.2025
4	0.9202	1.8142	-11.7813	-0.7024	4.1930	3.1820
5	0.9534	1.9342	-12.4572	-0.7053	4.1900	3.2038
6	1.3874	2.6651	-17.6107	-0.6947	4.0672	3.1564
7	1.3881	2.6735	-17.6173	-0.7087	4.1928	3.2247
8	1.3868	2.6713	-17.6254	-0.7059	4.1904	3.2137
9	1.3612	2.6291	-17.3222	-0.7047	4.1801	3.2112
10	1.3816	2.6601	-17.5634	-0.7057	4.2037	3.2069
ค่าเฉลี่ย	1.2873	2.4869	-16.3616	-0.7033	4.1584	3.1990
ค่าเบี่ยงเบนมาตรฐาน	0.1873	0.3279	2.2640*	0.0038	0.0478	0.0193

ตาราง 21 เวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกสำหรับชุดข้อมูลอัตราส่วน 80:20

รอบการทำซ้ำ	$h_1(\underline{d})$		$h_2(\underline{d})$			
	\bar{w}_1	b_1	\bar{w}_2	b_2		
1	0.9114	1.8475	-11.9549	-0.6987	4.1024	3.1676
2	1.3003	2.5068	-16.6038	-0.6959	4.0773	3.1740
3	1.3794	2.6561	-17.5235	-0.7056	4.1899	3.2067
4	1.2939	2.5034	-16.5258	-0.7077	4.1956	3.2356
5	1.3859	2.6676	-17.6019	-0.7060	4.1941	3.2085
6	0.9469	1.9271	-12.3939	-0.7051	4.1891	3.2128
7	1.3838	2.6703	-17.5835	-0.7084	4.1972	3.2303
8	1.4135	2.6516	-17.5049	-0.7052	4.1842	3.2097
9	1.3759	2.6563	-17.5008	-0.7073	4.1977	3.2255
10	1.3813	2.6587	-17.5638	-0.7044	4.1875	3.2029
ค่าเฉลี่ย	1.2772	2.4745	-16.2757	-0.7044	4.1715	3.2073
ค่าเบี่ยงเบนมาตรฐาน	0.1875	0.3165	2.2011*	0.0040	0.0436	0.0221


และเมื่อทดสอบซ้ำในอัตราส่วนชุดข้อมูลสอนและชุดทดสอบ 70:30 และ 80:20 ดังตาราง 19 และ 21 พบว่า ค่าเบี่ยงเบนมาตรฐานของเวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกที่หนึ่งมีค่าสูงกว่าสมการเส้นแบ่งแยกที่สอง เช่นเดียวกับที่พบในอัตราส่วนชุดข้อมูลสอนและชุดทดสอบ 60:40 แต่มีเบี่ยงเบนมาตรฐานของค่า b ลดลง 2.4825, 2.2640 และ 2.2011 ตามลำดับ และมีรอบการทำซ้ำที่แปรปรวนไปไม่เหมือนกัน คือ รอบการทำซ้ำที่ 4 กับ 5 สำหรับอัตราส่วน 70:30 และรอบการทำซ้ำที่ 1 กับ 6 สำหรับอัตราส่วน 80:20

ตาราง 22 เวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกกลุ่มข้อมูลแต่ละอัตราส่วน

อัตราส่วน	$h_1(d)$		$h_2(d)$			
	\bar{w}_1	b_1	\bar{w}_2	b_2		
60:40	1.2444	2.3892	-15.6855	-0.7030	4.1480	3.2083
70:30	1.2873	2.4869	-16.3616	-0.7033	4.1584	3.1990
80:20	1.2772	2.4745	-16.2757	-0.7044	4.1715	3.2073
ค่าเฉลี่ย	1.2697	2.4502	-16.1076	-0.7036	4.1593	3.2049
ค่าเบี่ยงเบนมาตรฐาน	0.0224	0.0532	0.3681	0.0008	0.0118	0.0051

เมื่อนำค่าเฉลี่ยเวกเตอร์ \bar{w} และค่า b ของแต่ละอัตราส่วนมาเปรียบเทียบกันดังตาราง 22 พบว่า ค่าเบี่ยงเบนมาตรฐานของเวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกที่สองมีค่าที่ต่ำมากที่สุด (0.0008, 0.0118) และ 0.0051 ตามลำดับ และมีค่าน้อยกว่าของสมการเส้นแบ่งแยกที่หนึ่งแต่เมื่อพิจารณาโดยรวมจะสังเกตเห็นว่า ค่าเบี่ยงเบนมาตรฐานของเวกเตอร์ \bar{w} และค่า b ของทั้งสองสมการเส้นแบ่งแยกมีค่าน้อยมากยกเว้นค่า b_1 ที่มีค่า 0.3681 ทำให้สามารถสรุปได้ว่าข้อมูลเวกเตอร์คุณลักษณะใหม่ d ที่ใช้ในการสร้างสมการแบ่งแยกทั้งสองไม่มีการเปลี่ยนแปลงไปตามจำนวนชุดข้อมูลสำหรับสอน และอาจสามารถใช้ค่าเฉลี่ยเวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกทั้งสองเป็นค่าสำหรับอัลกอริทึมการจำแนกโดยไม่ต้องทดสอบแยกในแต่ละอัตราส่วนได้ในการปรับปรุงงานวิจัยในอนาคต

ดังนั้นผู้วิจัยจึงใช้สมการเส้นแบ่งแยก $h_1(d)$ และ $h_2(d)$ ของเวกเตอร์คุณลักษณะใหม่ d ที่เกิดจากวิธีการซัพพอร์ตเวกเตอร์แมชชีนแบบสองคลาส ดังภาพที่ 36 ในการสร้างอัลกอริทึมสำหรับใช้ในการจำแนกสิ่งทอตามชนิดของเส้นใยออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์และกลุ่มผ้าเส้นใยผสม

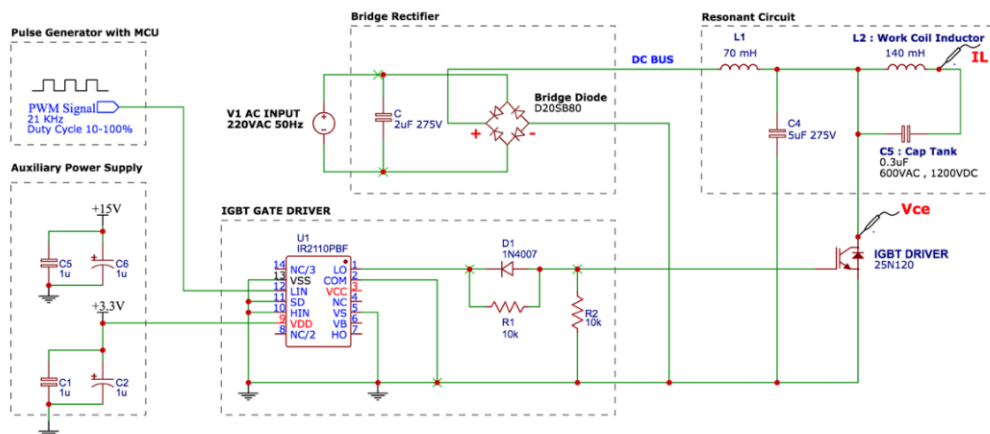


ภาพ 36 สมการเส้นแบ่งแยกของอัลกอริทึมการจำแนกด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน

4.2 ผลการวิจัยส่วนฮาร์ดแวร์ ที่ดำเนินการพัฒนาต้นแบบเตารีดไฟฟ้าที่ทำความร้อนด้วยการเหนี่ยวนำแบบกึ่งเรโซแนนท์


4.2.1. ผลการออกแบบและพัฒนางจรการเหนี่ยวนำแบบกึ่งเรโซแนนท์

ทำการออกแบบวงจรการเหนี่ยวนำแบบกึ่งเรโซแนนท์เพื่อสร้างแรงเคลื่อนเหนี่ยวนำและกระแสที่เกิดจากการเหนี่ยวนำของขดลวดเหนี่ยวนำไปเกิดเป็นความร้อนที่แผ่นพื้นเตารีด โดยใช้หน่วยประมวลผลไมโครคอนโทรลเลอร์ เป็นตัวควบคุมสัญญาณพัลส์ซับขาเกตของอุปกรณ์ IGBT ผ่านไอซี IC IR2110PBF เพื่อแก้ปัญหาแรงดันซับที่ขาเกตสำหรับฝั่ง High-Side รวมถึงข้อจำกัดเรื่องความถี่และสัญญาณรบกวนที่เกิดขึ้น ดังแสดงในภาพ 37




ภาพ 37 วงจรเหนี่ยวนำแบบกึ่งเรโซแนนท์ที่ควบคุมการทำงานด้วยไมโครคอนโทรลเลอร์


ทำการทดสอบการใช้ไมโครคอนโทรลเลอร์เพื่อสร้างสัญญาณพัลส์ซึบขาเกตที่มีความกว้างของลูกคลื่น (Duty cycle) ในช่วง 10 - 100% และความถี่ (Frequency) ในช่วงตั้งแต่ 10 - 100 kHz ผลการทดลองพบว่า ไมโครคอนโทรลเลอร์สามารถสร้างความกว้างของลูกคลื่นและความถี่ของสัญญาณซึบขาเกตได้ในช่วงที่กำหนดได้ ดังแสดงในภาพ 38 - 40




(ก) Duty cycle = 10%




(ข) Duty cycle = 20%




(ค) Duty cycle = 30%




(ง) Duty cycle = 40%




(จ) Duty cycle = 50%




(ฉ) Duty cycle = 60%



(ช) Duty cycle = 70%




(ซ) Duty cycle = 80%




(ณ) Duty cycle = 90%


ภาพ 38 ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นซึบขา Gate IGBT ที่ความถี่ 21 kHz




(ก) Duty cycle = 10%




(ข) Duty cycle = 20%



(ค) Duty cycle = 30%




(ง) Duty cycle = 40%




(จ) Duty cycle = 50%


ภาพ 39 ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นซึบขา Gate IGBT ที่ความถี่ 30 kHz




(ก) Duty cycle = 10%




(ข) Duty cycle = 20%



(ค) Duty cycle = 30%



(ง) Duty cycle = 40%



(จ) Duty cycle = 50%

ภาพ 40 ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นซึบขา Gate IGBT ที่ความถี่ 40 kHz

นำมาทดลองเพื่อหาค่ากระแสไฟฟ้าสูงสุด กระแสไฟฟ้าเฉลี่ยและระดับแรงดันคร่อมขาเกต IGBT ของวงจรที่พัฒนาขึ้น โดยกำหนดให้ใช้ความถี่คงที่ที่ 21 kHz และปรับเปลี่ยนค่าความกว้างของลูกคลื่น จากผลการทดลองพบว่าในช่วงของความกว้างของลูกคลื่น (Duty cycle) ที่มีมากกว่า 20% ขึ้นไปทำให้เกิดค่ากระแสไฟฟ้าสูงสุด (I_{pp}) สูงเกินค่าของอุปกรณ์ IGBT รุ่นที่เลือกใช้ในการพัฒนา ซึ่งทำให้เกิดปัญหาความร้อนและเกิดความเสียหายของอุปกรณ์ จึงทำการทดลองเพียงในช่วงความกว้างของลูกคลื่นตั้งแต่ 5 - 20% กว้าง โดยที่ LOAD 1 และ LOAD 2 จะเป็นวัสดุที่มีคุณสมบัติในการเหนี่ยวนำและขนาดพื้นที่หน้าตัดต่างกัน โดย LOAD 2 จะมีพื้นที่หน้าตัดมากกว่า LOAD 1 ดังแสดงในตาราง 23

ตาราง 23 ผลการเปลี่ยนแปลงความกว้างของลูกคลื่นและกำลังไฟฟ้าของวงจร

IGHT PWM		LOAD 1			LOAD 2		
Duty %	Freq. (kHz)	I_{pp} (A)	I_{rms} (A)	V_{ce} (V)	I_{pp} (A)	I_{rms} (A)	V_{ce} (V)
5	21	10.60	3.56	320	11.40	3.80	320
7	21	12.00	4.03	360	13.80	4.57	364
9	21	12.80	4.28	360	15.20	5.10	372
11	21	14.80	4.90	396	17.20	5.74	412
13	21	15.80	5.28	404	19.20	6.43	432
15	21	17.40	5.78	428	20.60	6.89	448
17	21	17.40	6.00	432	20.80	6.95	448
19	21	18.60	6.24	440	22.60	7.49	460

4.2.2. ผลเปรียบเทียบการใช้เซนเซอร์อุณหภูมิแบบสัมผัสและแบบไร้สัมผัสในการวัดค่าอุณหภูมิ




(ก) เซนเซอร์วัดอุณหภูมิ
RTD PT100 Class A

(ข) ตัวรับแปลงสัญญาณ
RTD PT100


(ค) เซนเซอร์อุณหภูมิแบบไม่
สัมผัส GY-906

ภาพ 41 เปรียบเทียบเซนเซอร์วัดอุณหภูมิของแผ่นพื้นเตารีดที่ใช้ในการทดลอง

ทำเปรียบเทียบการใช้เซนเซอร์แบบสัมผัส RTD PT100 Class A ดังภาพ 41 (ก) กับเซนเซอร์วัดอุณหภูมิแบบไร้สัมผัส (Non-Contact Sensor) ด้วยเซนเซอร์วัดอุณหภูมิแบบอินฟราเรด (Infrared Temperature) รุ่น GY-906 MLX90614ESF ดังภาพ 41 (ข) ในการวัดค่าอุณหภูมิเพื่อเป็นค่าป้อนกลับให้ไมโครคอนโทรลเลอร์ซึ่งทำหน้าที่ควบคุมการสร้างสัญญาณพัลส์ซบขาเกต IGBT ของวงจรการเหนี่ยวนำแบบกึ่งเรโซแนนท์ เนื่องจากในทดสอบ พบว่า เซนเซอร์แบบสัมผัส RTD PT100 มีปัญหาเรื่องระยะเวลาในการตอบสนองของอุณหภูมิซึ่งทำให้เกิดความคลาดเคลื่อนในการอ่านค่าของอุณหภูมิ ซึ่งเกิดจากหน้าสัมผัสของหัวโพรบที่มีลักษณะเป็นแผ่นทำให้ต้องใช้เวลาในการนำความร้อนผ่านแผ่นรองหัวโพรบ นอกจากนี้ขนาดของตัวแปลงรับสัญญาณของเซนเซอร์ RTD PT100 อาจส่งผลกระทบต่อการพัฒนาต้นแบบเตารีด ซึ่งต่างจากเซนเซอร์ GY-906 MLX90614ESF ที่มาขนาด (กว้างxยาว) เพียง 17 x 12 มิลลิเมตร



(ก) อุณหภูมิของแผ่นพื้นเตารีดที่ Duty Cycle ต่าง ๆ โดยวัดด้วยเซนเซอร์ RTD PT100



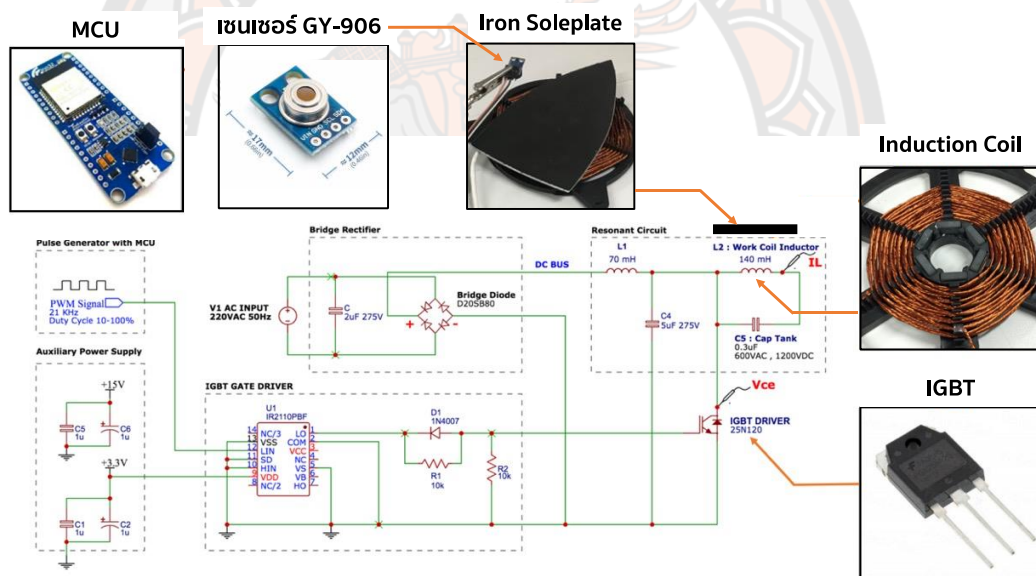
(ข) อุณหภูมิของแผ่นพื้นเตารีดที่ Duty Cycle ต่าง ๆ โดยวัดด้วยเซนเซอร์ GY-906

ภาพ 42 เปรียบเทียบเซนเซอร์ที่ใช้ในการวัดอุณหภูมิของแผ่นพื้นเตารีด


จากภาพ 42 แสดงอุณหภูมิของแผ่นพื้นเตารีดที่เกิดจากความกว้างลูกคลื่น (Duty Cycle) ของสัญญาณขับขาเกต IGBT วงจรการเหนี่ยวนำแบบกึ่งเรโซแนนท์ในช่วงที่แตกต่างกัน โดยใช้ขดลวดเหนี่ยวนำและวัสดุที่เป็นโพลีเอทิลีน และควบคุมให้ระบบทำความร้อนจนถึงอุณหภูมิที่กำหนดไว้ที่ 100 องศาเซลเซียส (Temperature Set-Point) โดยทำการจัดเก็บข้อมูลอุณหภูมิเปรียบเทียบกันระหว่างการใช้เซนเซอร์แบบสัมผัส RTD PT100 และเซนเซอร์ไม่สัมผัส GY-906 พบว่า เมื่อสั่งงานสัญญาณควบคุมขาเกตที่ความกว้างลูกคลื่น 15% เหมือนกันเซนเซอร์แบบโพรบ RTD PT100 อ่านค่าอุณหภูมิได้ 100 องศาเซลเซียสที่เวลา 75 วินาที ดังภาพ 42 (ก) ในขณะที่เซนเซอร์แบบไร้สัมผัส GY-906 อ่านค่าอุณหภูมิได้ที่เวลา 27 วินาที ดังภาพ 42 (ข) ซึ่งให้ค่าใกล้เคียงตรงกับเครื่องมือที่ใช้ในการเปรียบเทียบวัดค่า INFRARED THERMOMETER ยี่ห้อ UNI-T รุ่น

UT300S นอกจากนี้เมื่อสังเกตจุดที่อุณหภูมิอ่านค่าได้ 100 องศาเซลเซียส ระบบควบคุมการเหนี่ยวนำความร้อนจะหยุดทำความร้อนเซนเซอร์ แบบโพรบ RTD PT100 อุณหภูมิยังคงขึ้นสูงไปจนถึงประมาณ 120 องศาเซลเซียสจากนั้นจึงเริ่มลดลง ซึ่งแตกต่างจากผลของเซนเซอร์แบบไร้สัมผัส GY-906 ในดั่งภาพ 42 (ข) ที่เมื่อหยุดการทำงานของระบบอุณหภูมิจะสูงขึ้นประมาณ 105 ถึง 107 องศาเซลเซียส จากนั้นอุณหภูมิจะลดลงแสดงให้เห็นว่า เซนเซอร์แบบโพรบ RTD PT100 ไม่เหมาะสมต่อระยะเวลาในการตอบสนองของการเปลี่ยนแปลงอุณหภูมิของเตารีดที่ความเร็วในการเปลี่ยนแปลง นอกจากนี้ความกว้างลูกคลื่น (Duty Cycle) ของสัญญาณขับขาเกต IGBT ที่เพิ่มมากขึ้น ช่วยลดระยะเวลาในการทำความร้อน (Raising-Up) ของแผ่นพื้นเตารีดให้ไปถึงอุณหภูมิที่กำหนด

ดังนั้นผู้วิจัยจึงใช้เซนเซอร์แบบไม่สัมผัส Infrared Temperature GY-906 ในการตรวจวัดอุณหภูมิแผ่นพื้นเตารีดเพื่อใช้เป็นค่าป้อนกลับสำหรับการควบคุมวงจรการเหนี่ยวนำแบบกึ่งเรโซแนนซ์ให้มีค่าอุณหภูมิอยู่ในช่วงที่กำหนด ดังแสดงส่วนประกอบต่าง ๆ ของวงจรในภาพ 43




(ก) Circuit Diagram และอุปกรณ์ของวงจรการเหนี่ยวนำแบบกึ่งเรโซแนนซ์ด้วย IGBT ที่ควบคุมอุณหภูมิตามที่กำหนดด้วยไมโครคอนโทรลเลอร์และเซนเซอร์แบบไม่สัมผัส




(ข) ต้นแบบวงจรการเหนี่ยวนำแบบกึ่งเรโซแนนซ์ด้วย IGBT ที่ควบคุมอุณหภูมิตามที่กำหนดด้วยไมโครคอนโทรลเลอร์และเซนเซอร์แบบไม่สัมผัส

ภาพ 43 วงจรและต้นแบบเตารีดอัจฉริยะที่ควบคุมอุณหภูมิตามที่กำหนดโดยอัตโนมัติ


ผู้วิจัยได้ทำการปรับปรุงวงจรที่พัฒนาในขั้นตอนที่สามให้มีขนาดเล็กลงให้สามารถบรรจุอยู่ในเตารีด และมีขนาดเท่ากับผลิตภัณฑ์จริงที่มีจำหน่ายทั่วไป โดยเฉพาะในส่วนของขดลวดเหนี่ยวนำ (Induction Coil) ที่ทำการออกแบบตัวบรรจุขดลวดเหนี่ยวนำดังแสดงในภาพ 44 (ก-ค) และทดสอบติดตั้ง ดังแสดงในภาพ 44 (ง-ฉ)



(ก) แบบตัวบรรจุขดลวด




(ข) การติดตั้งกับแผ่นพื้น



(ค) ตัวบรรจุขดลวดเหนี่ยวนำ



(ง) การติดตั้งขดลวด



(จ) การติดตั้งขดลวด



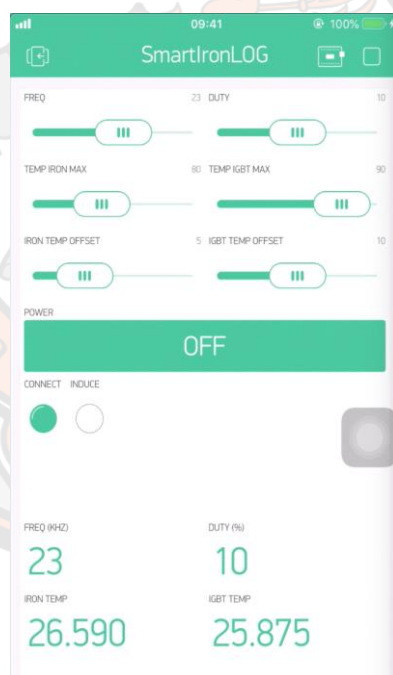
(ฉ) การติดตั้งขดลวด

ภาพ 44 ต้นแบบเตารีดไฟฟ้าอัจฉริยะที่พัฒนา

4.2.3. ผลการพัฒนา Mobile Application ในการควบคุมต้นแบบเตารีดอัจฉริยะ

ทำการพัฒนา Mobile Application ที่สามารถเชื่อมต่อกับบอร์ดไมโครคอนโทรลเลอร์ (MCU: Microcontroller Unit) ที่ใช้ในการควบคุมสัญญาณพัลส์ซ้บขาเกต IGBT ของวงจรการเหนี่ยวนำความร้อนแบบกึ่งเรโซแนนซ์ที่พัฒนา เพื่อใช้ในการกำหนดค่าพารามิเตอร์อินพุตของระบบในการทดสอบการควบคุมอุณหภูมิ และให้สอดคล้องกับประเด็นปัญหาที่ต้องการพัฒนาต้นแบบเครื่องใช้ไฟฟ้าอัจฉริยะที่สามารถเชื่อมต่อกับอุปกรณ์ผ่านระบบเครือข่ายอินเทอร์เน็ต (IoT) โดยสามารถปรับเปลี่ยนค่าพารามิเตอร์ในการทดสอบดังแสดงในภาพ 45 ได้ดังนี้

1. ค่าความกว้างลูกคลื่นของสัญญาณพัลส์ซ้บขาเกต IGBT ของวงจร
2. ค่าความถี่ (Frequency) ของสัญญาณพัลส์ซ้บขาเกต IGBT ของวงจร
3. ค่าช่วงอุณหภูมิของแผ่นพื้นเตารีดที่ต้องการควบคุม
4. ค่าช่วงอุณหภูมิของอุปกรณ์ IGBT ที่ต้องการควบคุมเพื่อความปลอดภัยของวงจร



ภาพ 45 หน้าจอ Mobile Application ที่ใช้ในการควบคุมต้นแบบเตารีดอัจฉริยะ

นอกจากนี้เอาท์พุทผลลัพธ์ของการทดลองหลังปรับค่าพารามิเตอร์ ได้แก่ 1) อุณหภูมิของแผ่นพื้นเตารีด 2) อุณหภูมิของอุปกรณ์ IGBT ซึ่งจะส่งผลกระทบต่อประสิทธิภาพและความสามารถในการทำงานของวงจร และ 3) สถานะการทำงานของวงจร (การเหนี่ยวนำให้เกิดความร้อนของที่แผ่นพื้นเตารีด) จะถูกส่งไปเก็บเป็น Data Log ที่ Web Application ที่ผู้วิจัยพัฒนาขึ้น เพื่อนำมาวิเคราะห์ผลดูของช่วงเวลาในการทำความร้อน (Raising-Up) และช่วงเวลาในการเย็นตัวลง


(Cooling-Down) ของแผ่นพื้นเตารีดเมื่อทำการกำหนดค่าความกว้างลูกคลื่น (Duty Cycle) และ ค่าความถี่ (Frequency) ต่าง ๆ ดังแสดงในภาพ 46



ภาพ 46 หน้าจอการทำงานของ Web Application เก็บ Data Log


4.2.4. ผลการควบคุมอุณหภูมิที่แผ่นพื้นเตารีดให้อยู่ในช่วงอุณหภูมิที่กำหนด

จากภาพ 47 แสดงผลการควบคุมอุณหภูมิที่แผ่นพื้นเตารีดให้อยู่ในช่วงอุณหภูมิ 60 ถึง 70 องศาเซลเซียส โดยใช้ความกว้างลูกคลื่น (Duty Cycle) 10% และความถี่ (Frequency) ที่ 23 kHz ของสัญญาณพัลส์ซับขาเกต IGBT ซึ่งผลลัพธ์แสดงให้ว่า ระบบสามารถควบคุมช่วงอุณหภูมิให้อยู่ในช่วงที่กำหนดได้คงที่ แต่จะพบว่าในช่วงเริ่มต้นที่อุณหภูมิของแผ่นพื้นเริ่มจาก 30 องศาเซลเซียส อุปกรณ์ IGBT จะมีอุณหภูมิสูงจนเกิดขีดจำกัดการทำงานของตัวเอง ระบบจึงตัดการทำงานของวงจรก่อนทำให้อุณหภูมิของแผ่นพื้นเตารีดยังไม่ถึง 70 องศาเซลเซียส และหลังจากแผ่นพื้นเตารีดมีอุณหภูมิอยู่ในช่วงที่ต้องการควบคุม อุณหภูมิของอุปกรณ์ IGBT จึงทำงานน้อยลงและมีอุณหภูมิต่ำลง และผลจากกราฟทำให้ พบว่า ช่วงเวลาในการทำความร้อน (Raising-Up) จะมีค่าประมาณ 40 - 70 วินาที ในช่วงเริ่มต้น และใช้เวลาประมาณ 10 วินาที ในกรณีที่ควบคุมอุณหภูมิในช่วงได้แล้ว ส่วนช่วงเวลาในการเย็นตัวลง (Cooling-Down) จะมีค่าประมาณ 40 - 75 วินาทีในการเปลี่ยนจากอุณหภูมิ 70 องศาเซลเซียสถึง 60 องศาเซลเซียส



ภาพ 47 ผลการควบคุมอุณหภูมิแผ่นฟิเนตารีตในช่วง 60 °C จนถึง 70 °C

เมื่อทดลองเปลี่ยนช่วงของอุณหภูมิที่ต้องการควบคุมให้ลดลงให้อยู่ในช่วง 5 องศาเซลเซียส คือ 75 จนถึง 80 เซลเซียส โดยใช้ความกว้างลูกคลื่น (Duty Cycle) 10% และปรับเปลี่ยนความถี่ (Frequency) ของสัญญาณพัลส์ขับขาเกต IGBT เป็น 29 kHz ซึ่งเป็นความถี่ Resonant ของวงจรการเหนี่ยวนำความร้อนแบบกึ่งเรโซแนนท์ ทำให้ได้ผลลัพธ์ของการควบคุมอุณหภูมิ ดังแสดงในภาพ 48 พบว่า ระบบสามารถควบคุมอุณหภูมิให้อยู่ในช่วงที่กำหนดได้และช่วงเวลาในการทำความร้อน (Raising-Up) มีค่าลดลงเหลือประมาณ 30 วินาที



ภาพ 48 ผลการควบคุมอุณหภูมิแผ่นฟิเนตารีตในช่วง 75 °C จนถึง 80 °C

จากผลการทดสอบแสดงให้เห็นว่าการควบคุมอุณหภูมิโดยใช้การป้อนกลับจากเซนเซอร์แบบไร้สัมผัส สามารถทำให้ต้นแบบเตาไร้ดัดอัจฉริยะสามารถควบคุมอุณหภูมิให้อยู่ในช่วงระหว่าง ± 5 องศาเซลเซียสของอุณหภูมิที่กำหนดได้โดยอัตโนมัติตาม ด้วยการปรับความกว้างลูกคลื่นในช่วง 0 ถึง 100% ของสัญญาณพัลส์ขับขาเกตจากไมโครคอนโทรลเลอร์ นอกจากนี้การวิจัยยังพบว่า การปรับเปลี่ยนความกว้างลูกคลื่นและความถี่ของสัญญาณพัลส์ขับขาเกต IGBT มีผลต่อช่วงเวลาในการทำความร้อน (Raising-Up) ของแผ่นพื้นเตาไร้ดัด

4.3 ผลการวัดประสิทธิภาพอัลกอริทึมในการจำแนกสิ่งทอตามชนิดผ้า

ทำการวัดประสิทธิภาพอัลกอริทึมการจำแนกโดยใช้ชุดข้อมูลทดสอบที่แบ่งในขั้นตอนการพัฒนาอัลกอริทึมนำมาผ่านกระบวนการสร้างเวกเตอร์คุณลักษณะใหม่ \underline{d} ด้วยวิธีการที่นำเสนอ คือ การนอร์มอลไลซ์สเปกตรัม จากนั้นนำไปสร้างเวกเตอร์คุณลักษณะใหม่ ด้วยการใช้เซตตำแหน่งความถี่ \mathcal{K} และเวกเตอร์ตัวแทนคุณลักษณะ $\underline{f}_n, \underline{f}_s$ ของกลุ่มเส้นในธรรมชาติและกลุ่มเสียยีสักราะห์ เพื่อจำแนกสิ่งทอตามชนิดของเส้นใย โดยใช้ค่าเวกเตอร์ \underline{w} และค่า b ของสมการเส้นแบ่งแยก $h_1(\underline{d})$ และ $h_2(\underline{d})$ จากขั้นตอนการพัฒนาอัลกอริทึมของแต่ละรอบการสุ่มทำซ้ำทั้ง 10 รอบจากอัตราส่วนชุดข้อมูลสอนและชุดข้อมูลทดสอบ 60:40, 70:30 และ 80:20 ตามลำดับ โดยใช้ตาราง Confusion Matrix แบบ multi-class ที่ออกแบบไว้ในบทที่ 3 เพื่อเก็บค่าผลลัพธ์การจำแนกในรูปแบบค่า True Positive (TP), False Positive (FP), True Negative (TN) และ False Negative (FN) ทำให้ได้ผลลัพธ์แสดงดังตาราง 24 ถึง 26

ตาราง 24 Confusion Matrix แบบ Multi-class ของการทดสอบอัตราส่วน 60:40

รอบการทดสอบ	กลุ่มเส้นใยธรรมชาติ				กลุ่มเส้นใยสังเคราะห์				กลุ่มเส้นใยผสม			
	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN
1	84	0	0	300	192	0	0	192	108	0	0	276
2	84	0	0	300	192	0	0	192	108	0	0	276
3	84	0	0	300	192	0	0	192	108	0	0	276
4	84	0	0	300	192	0	0	192	108	0	0	276
5	84	0	0	300	192	0	0	192	108	0	0	276
6	84	0	0	300	192	0	0	192	108	0	0	276
7	84	0	0	300	192	0	0	192	108	0	0	276
8	84	0	0	300	192	0	0	192	108	0	0	276
9	84	0	0	300	192	0	0	192	108	0	0	276
10	84	0	0	300	192	0	0	192	108	0	0	276

เวกเตอร์คุณลักษณะใหม่ d ของชุดทดสอบในอัตราส่วน 60:40 มีจำนวนข้อมูลที่ใช้ทดสอบรวมทั้งหมด 384 ข้อมูล โดยแบ่งออกเป็นข้อมูลกลุ่มเส้นใยธรรมชาติ กลุ่มเส้นใยสังเคราะห์และกลุ่มเส้นใยผสมเท่ากับ 84, 192 และ 108 ข้อมูลตามลำดับ จากตารางที่ 30 พบว่า ทุกกลุ่มเส้นใยมีค่า False Negative (FN) และ False Positive (FP) เป็นศูนย์ ซึ่งแสดงให้เห็นว่า อัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใยที่นำเสนอไม่เกิดข้อผิดพลาดในการจำแนกคลาสเกิดขึ้นในทุกการสุ่มซ้ำเพื่อทดสอบ โดยสังเกตจากกลุ่มเส้นใยธรรมชาติที่มีค่า True Positive (TP) เท่ากับ 84 ซึ่งเท่ากับจำนวนข้อมูลทั้งหมดของกลุ่มเส้นใยธรรมชาติ แสดงว่าสามารถจำแนกข้อมูลกลุ่มเส้นใยธรรมชาติเป็นคลาสกลุ่มเส้นใยธรรมชาติได้ถูกต้องทั้งหมด และมีค่า True Negative (TN) เท่ากับ 300 แสดงว่า สามารถจำแนกข้อมูลกลุ่มที่ไม่ใช่กลุ่มเส้นใยธรรมชาติเป็นกลุ่มเส้นใยสังเคราะห์ (192) และกลุ่มเส้นใยผสม (108) ได้ถูกต้องทั้งหมดตามลำดับ ดังนั้นเมื่อพิจารณาที่กลุ่มเส้นใยสังเคราะห์จึงมีค่า True Positive (TP) เท่ากับ 192 ซึ่งเท่ากับจำนวนข้อมูลทั้งหมดของกลุ่มเส้นใยสังเคราะห์ และมีค่า True Negative (TN) เท่ากับ 192 ซึ่งเท่ากับจำนวนของข้อมูลกลุ่มที่ไม่ใช่กลุ่มเส้นใยสังเคราะห์ คือ กลุ่มเส้นใยธรรมชาติ (84) และกลุ่มเส้นใยผสม (108) และเป็นไปในทำนองเดียวกันกับกลุ่มเส้นใยผสม แสดงให้เห็นว่าอัลกอริทึมที่นำเสนอมีประสิทธิภาพในการจำแนกทั้ง 3 กลุ่มเส้นใยได้อย่างชัดเจน

ตาราง 25 Confusion Matrix แบบ Multi-class ของการทดสอบอัตราส่วน 70:30

รอบการทดสอบ	กลุ่มเส้นใยธรรมชาติ				กลุ่มเส้นใยสังเคราะห์				กลุ่มเส้นใยผสม			
	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN
1	63	0	0	225	144	0	0	144	81	0	0	207
2	63	0	0	225	144	0	0	144	81	0	0	207
3	63	0	0	225	144	0	0	144	81	0	0	207
4	63	0	0	225	144	0	0	144	81	0	0	207
5	63	0	0	225	144	0	0	144	81	0	0	207
6	63	0	0	225	144	0	0	144	81	0	0	207
7	63	0	0	225	144	0	0	144	81	0	0	207
8	63	0	0	225	144	0	0	144	81	0	0	207
9	63	0	0	225	144	0	0	144	81	0	0	207
10	63	0	0	225	144	0	0	144	81	0	0	207

ตาราง 26 Confusion Matrix แบบ Multi-class ของการทดสอบอัตราส่วน 80:20

รอบการทดสอบ	กลุ่มเส้นใยธรรมชาติ				กลุ่มเส้นใยสังเคราะห์				กลุ่มเส้นใยผสม			
	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN
1	42	0	0	150	96	0	0	96	54	0	0	138
2	42	0	0	150	96	0	0	96	54	0	0	138
3	42	0	0	150	96	0	0	96	54	0	0	138
4	42	0	0	150	96	0	0	96	54	0	0	138
5	42	0	0	150	96	0	0	96	54	0	0	138
6	42	0	0	150	96	0	0	96	54	0	0	138
7	42	0	0	150	96	0	0	96	54	0	0	138
8	42	0	0	150	96	0	0	96	54	0	0	138
9	42	0	0	150	96	0	0	96	54	0	0	138
10	42	0	0	150	96	0	0	96	54	0	0	138

และเมื่อพิจารณาผลลัพธ์จากตาราง 24-26 ที่ใช้อัตราส่วนชุดข้อมูลสอนและชุดข้อมูลทดสอบที่เปลี่ยนไปเป็น 70:30 และ 80:20 ตามลำดับ พบว่า ทุกกลุ่มเส้นใยมีค่า False Negative (FN) และ False Positive (FP) เป็นศูนย์ เช่นเดียวกับอัตราส่วน 60:40 แสดงให้เห็นว่าจำนวนข้อมูลที่ใช้ในการสอนไม่มีผลต่อการจำแนกข้อมูล โดยในทุกอัตราส่วนและการทำซ้ำจะได้ค่า True Positive (TP) เท่ากับจำนวนข้อมูลทั้งหมดของกลุ่มเส้นใยที่กำลังพิจารณา เช่น ชุดข้อมูลอัตราส่วน 70:30 มีจำนวนข้อมูลที่ใช้ทดสอบรวมทั้งหมด 288 ข้อมูล โดยแบ่งออกเป็นข้อมูลกลุ่มเส้นใยธรรมชาติ กลุ่มเส้นใยสังเคราะห์และกลุ่มเส้นใยผสมเท่ากับ 63, 144 และ 81 ข้อมูลตามลำดับ ดังตาราง 25และเท่ากับ 42, 96 และ 54 สำหรับชุดข้อมูลอัตราส่วน 80:20 ที่มีจำนวนข้อมูลที่ใช้ทดสอบรวมทั้งหมด 192 ข้อมูล ดังตาราง 26 นอกจากนี้ในทุกอัตราส่วนและการทำซ้ำจะได้ค่า True Negative (TN) ของคลาสนั้นเท่ากับจำนวนทั้งหมดของกลุ่มข้อมูลทั้งหมดที่ไม่ได้พิจารณารวมกัน เช่น TN ของคลาสกลุ่มเส้นใยธรรมชาติเท่ากับ 150 คือจำนวนของกลุ่มเส้นใยสังเคราะห์และกลุ่มเส้นใยผสมรวมกัน

จากนั้นนำค่า Confusion Matrix ของตารางที่ 24-26 เพื่อหาประสิทธิภาพของอัลกอริทึมการจำแนกด้วยค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าความถูกต้อง (Accuracy) ทำให้ได้ผลลัพธ์ดังตาราง 27 ถึง 29

ตาราง 29 ประสิทธิภาพอัลกอริทึมการจำแนกสิ่งทอด้วยชุดข้อมูลทดสอบอัตราส่วน 80:20

รอบการทดสอบ	กลุ่มเส้นใยธรรมชาติ			กลุ่มเส้นใยสังเคราะห์			กลุ่มเส้นใยผสม		
	Precisio n	Recall	Accurac y	Precisio n	Recall	Accurac y	Precision	Recall	Accurac y
1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
2	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
3	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
4	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
5	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
6	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
7	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
8	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
9	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
10	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
μ	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
σ	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

จากตาราง 29 พบว่า ชุดข้อมูลทดสอบอัตราส่วน 80:20 ในทุกรอบการทำซ้ำจะได้ค่า ความแม่นยำ (Precision) และค่าความระลึก (Recall) เป็น 1.00 ของทุกกลุ่มเส้นใย ซึ่งแสดงให้เห็นว่า อัลกอริทึมการจำแนกสิ่งทอที่นำเสนอมีความแม่นยำในการจำแนกกลุ่มข้อมูลกลุ่มเส้นใยที่กำลังพิจารณาได้อย่างถูกต้อง และปฏิเสธกลุ่มข้อมูลที่ไม่ได้พิจารณาเป็นกลุ่มข้อมูลจริงของคลาสนั้นๆ ได้อย่างถูกต้อง ซึ่งเป็นผลจากผลลัพธ์ของตาราง 26 ซึ่งมีค่า False Positive (FP) และ False Positive (FP) เป็นศูนย์ รวมถึงค่า True Positive (TP) เท่ากับจำนวนข้อมูลทั้งหมดของกลุ่มเส้นใยที่กำลังพิจารณา จึงส่งผลให้ค่าความถูกต้อง (Accuracy) ของทุกกลุ่มเส้นใยมีค่าเป็น 1.00 นอกจากนี้เมื่อพิจารณาชุดข้อมูลทดสอบอัตราส่วน 70:30 และ 60:40 ที่มีจำนวนข้อมูลที่ใช้ในการสอนลดลง อัลกอริทึมการจำแนกสิ่งทอที่นำเสนอยังคงมีค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าความถูกต้อง (Accuracy) ของทุกกลุ่มเส้นใยมีค่าเป็น 1.00 แสดงให้เห็นว่าจำนวนข้อมูลที่ใช้ในการสอนแบบจำลองและข้อมูลใหม่ที่ไม่มีในแบบจำลอง ไม่ส่งผลต่อประสิทธิภาพของอัลกอริทึมการจำแนกที่ผู้วิจัยนำเสนอ

บทที่ 5

บทสรุป

5.1 สรุปผลการวิจัย

อัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยโดยใช้ข้อมูลสเปกตรัมในย่านใกล้อินฟราเรด ช่วงความยาวคลื่น 1,350 ถึง 2,500 นาโนเมตร จากเซนเซอร์สเปกตรัม NeoSpectra-Micro รุ่น SWS62231 ของบริษัท Si-Ware System ที่ผู้วิจัยนำเสนอสามารถจำแนกสิ่งทอออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าเส้นใยผสมได้ โดยในการพัฒนาอัลกอริทึมใช้ตัวอย่างผ้าที่นิยมใช้ในการตัดเย็บเสื้อผ้าจากโรงงานหรือแหล่งจำหน่ายในประเทศไทย และผ่านการตรวจสอบยืนยันองค์ประกอบของเส้นใยตามมาตรฐาน มอก.121 เล่ม 26-2552 จำนวนทั้งหมด 96 ผืน เพื่อนำมาใช้ในการเก็บข้อมูลสัญญาณสเปกตรัมตัวอย่างผ้า จำนวน 960 สัญญาณสเปกตรัม และแบ่งชุดข้อมูลออกเป็น 2 ส่วน คือ ชุดข้อมูลสำหรับสอนในส่วนการพัฒนาอัลกอริทึมกับชุดข้อมูลสำหรับทดสอบในส่วนการวัดประสิทธิภาพอัลกอริทึม ในอัตราส่วนที่แตกต่าง 3 อัตราส่วน คือ 60:40, 70:30 และ 80:20 การพัฒนาอัลกอริทึมการจำแนกแบ่งออกเป็น 3 ขั้นตอนหลัก คือ ขั้นตอนการเตรียมสัญญาณสเปกตรัมนำเข้าให้อยู่ในรูปลำดับข้อมูลที่มี 65 ข้อมูลต่อสเปกตรัม ขั้นตอนการสกัดเวกเตอร์คุณลักษณะใหม่ที่ใช้เทคนิคการประมวลผลสัญญาณและการวิเคราะห์สัญญาณในโดเมนความถี่ เพื่อหาคุณลักษณะเด่นของสัญญาณผ้าในแต่ละกลุ่มเส้นใย โดยทำการสร้างสัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัมของกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ที่มีค่าพลังงานรวมของลำดับสัญญาณเท่ากันเท่ากันทำให้สามารถใช้เปรียบเทียบกันได้ ด้วยการลบแต่ละสัญญาณด้วยค่าเฉลี่ยของตัวสัญญาณแล้วนำมาหาค่าสัญญาณเฉลี่ยของแต่ละกลุ่มและหารด้วยแอมพลิจูดของตัวสัญญาณเฉลี่ย จากนั้นทำการแปลงสัญญาณตัวแทนนอร์มอลไลซ์สเปกตรัมทั้งสองให้อยู่ในรูปส่วนจริงของอนุกรมฟูเรียร์ของลำดับคาบ เพื่อเปรียบเทียบหาตำแหน่งดัชนีความถี่ใด ๆ ที่ค่าขนาดข้อมูลมีเครื่องหมายแตกต่างกัน และมีค่าความต่างของขนาดข้อมูลมากกว่าค่า -3dB ซึ่งงานวิจัย พบว่า ดัชนีความถี่ที่ตำแหน่ง 2, 3, 4 และ 13 เป็นไปตามเงื่อนไขสำหรับในทุก ๆ อัตราส่วนของชุดข้อมูลสอน โดยมีค่าเบี่ยงเบนมาตรฐานเท่ากับ 0.0010, 0.0011, 0.0008 และ 0.0005 ตามลำดับ จึงใช้ดัชนีตำแหน่งเหล่านี้เป็นเขตตำแหน่งความถี่ในการเลือกค่าลำดับข้อมูลส่วนจริงของอนุกรมฟูเรียร์ของลำดับคาบของสัญญาณตัวแทนทั้งสองทำให้ได้เวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและเวกเตอร์ตัวแทนกลุ่มเส้นใยสังเคราะห์ สำหรับใช้ในการสร้างเวกเตอร์คุณลักษณะใหม่กับเวกเตอร์ของสัญญาณสเปกตรัมนำเข้าใด ๆ ซึ่งเกิดจากสัญญาณสเปกตรัมนำเข้าใด ๆ ที่ผ่านการนอร์

มอลโลซิสเปกตรัมและแปลงให้อยู่ในรูปส่วนจริงของอนุกรมฟูเรียร์ของลำดับคาบและเลือกค่าลำดับข้อมูลเฉพาะเซตตำแหน่งความถี่ เดียวกันกับเวกเตอร์ตัวแทนกลุ่ม ทำให้ได้เวกเตอร์คุณลักษณะใหม่ที่มีจำนวนข้อมูลลดลงเป็นเวกเตอร์ขนาด 2×1 ที่จะแสดงถึงระยะห่างของเวกเตอร์นำเข้าใดๆ กับเวกเตอร์กับเวกเตอร์ตัวแทนกลุ่มเส้นในธรรมชาติและกลุ่มเส้นใยสังเคราะห์ตามลำดับด้วยวิธีแอลพินอร์ม จากขั้นตอนการสกัดเวกเตอร์คุณลักษณะที่ผู้วิจัยนำเสนอในขั้นตอนนี้แสดงให้เห็นถึงจำนวนข้อมูลนำเข้าในการสร้างแบบจำลองการจำแนกที่ลดลงจาก 65 ข้อมูลต่อสเปกตรัมเหลือเพียงเวกเตอร์ขนาด 2×1 ซึ่งจะส่งผลกระทบต่อต้นทุนและทรัพยากรในการคำนวณอย่างชัดเจน ในขั้นตอนนี้สุดท้ายผู้วิจัยใช้เวกเตอร์คุณลักษณะใหม่ที่เกิดขึ้นเป็นอินพุตนำเข้าในการสร้างแบบจำลองการจำแนกด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบ 3 คลาสที่ผู้วิจัยนำเสนอแทนการใช้วิธีการตัดแยกทีละหนึ่งต่อหนึ่ง (One-against-One) ซึ่งต้องมีจำนวนสมการเส้นแบ่งแยก 3 สมการเท่ากับจำนวนคลาสที่ต้องการจำแนก ด้วยการสร้างสมการ เส้นแบ่งแยกเพียง 2 สมการ คือ สมการเส้นแบ่งแยกหนึ่งที่ใช้กลุ่มข้อมูลเส้นใยธรรมชาติเป็น Positive Class และใช้ข้อมูลกลุ่มเส้นใยผสมกับสังเคราะห์เป็น Negative Class และในส่วนสมการเส้นแบ่งแยกสอง ที่ใช้กลุ่มข้อมูลเส้นใยธรรมชาติและผสมเป็น Positive Class และข้อมูลกลุ่มเส้นใยสังเคราะห์เป็น Negative Class โดยงานวิจัยพบว่า ค่าเบี่ยงเบนมาตรฐานของเวกเตอร์ \bar{w} และค่า b ของสมการเส้นแบ่งแยกทั้งสอง จากทุกอัตราส่วนข้อมูลสอนต่อการทดสอบ มีค่าเท่ากับ (0.0224, 0.0532), 0.3681 และ (0.0008, 0.0118), 0.0051 ตามลำดับ ซึ่งแสดงให้เห็นว่าสมการเส้นแบ่งแยกกลุ่มข้อมูลจากเวกเตอร์คุณลักษณะใหม่ที่เกิดขึ้นไม่ขึ้นกับกับจำนวนของข้อมูลที่ใช้สร้างแบบจำลองที่เปลี่ยนแปลงไป ผู้วิจัยจึงใช้สมการเส้นแบ่งแยกทั้งสองพัฒนาอัลกอริทึมในการจำแนกสิ่งทอด้วยผลลัพธ์สมการเส้นแบ่งแยกทั้งสองจากอินพุตเวกเตอร์คุณลักษณะใหม่ โดยจะจำแนกเป็นสิ่งทอในกลุ่มเส้นใยธรรมชาติเมื่อผลลัพธ์สมการเส้นแบ่งแยกที่หนึ่งมากกว่าศูนย์ และจำแนกเป็นสิ่งทอในกลุ่มเส้นใยสังเคราะห์เมื่อผลลัพธ์สมการเส้นแบ่งแยกที่สองน้อยกว่าศูนย์ หากไม่ตรงกับเงื่อนไขทั้งสองจะจำแนกเป็นสิ่งทอในกลุ่มเส้นใยผสม

ในส่วนการวัดประสิทธิภาพของอัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยออกเป็น 3 กลุ่มคือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าเส้นใยผสม ผู้วิจัยใช้ชุดข้อมูลสำหรับทดสอบจากทั้ง 3 อัตราส่วน เพื่อวิเคราะห์ผลกระทบของประสิทธิภาพการจำแนกที่เปลี่ยนแปลงไปจากจำนวนข้อมูลที่ใช้ในการสร้างแบบจำลอง โดยทำสร้างเวกเตอร์คุณลักษณะใหม่จากสเปกตรัมนำเข้าใด ๆ ของชุดข้อมูลทดสอบ ด้วยขั้นตอนวิธีการและค่าพารามิเตอร์ที่ได้จากขั้นตอนการพัฒนาอัลกอริทึมตามลำดับ กล่าวคือ การทำนอร์มอลโลซิสเปกตรัม การแปลงสเปกตรัมให้อยู่ในรูปส่วนจริงของอนุกรมฟูเรียร์ของลำดับคาบและเลือกค่าลำดับข้อมูลเฉพาะในเซตดัชนีความถี่ จากนั้นนำไปสร้างเวกเตอร์คุณลักษณะใหม่จากเวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและกลุ่มเส้นใยสังเคราะห์ ทำให้ได้เวกเตอร์คุณลักษณะใหม่ที่จะใช้เปรียบเทียบกับอัลกอริทึมในการจำแนกสิ่งทอตาม

ชนิดของเส้นใยที่นำเสนอด้วยสมการเส้นแบ่งแยกทั้งสอง แล้วเก็บผลลัพธ์การจำแนกลงในตาราง Confusion Matrix แบบหลายคลาสในรูปแบบของค่า True Positive (TP), False Negative (FN), True Negative (TN), และ False Positive (FP) ที่ผู้วิจัยออกแบบในบทที่ 3 และใช้เครื่องมือในการวัดประสิทธิภาพจำนวน 3 ตัว ได้แก่ ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าความถูกต้องรวมทั้งระบบ (Overall Accuracy) ผลวิจัยพบว่า ประสิทธิภาพของอัลกอริทึมในการจำแนกสิ่ง ทอตามชนิดของเส้นใยที่นำเสนอของทุกคลาสดูแลเส้นใย มีค่าความแม่นยำ (Precision) และค่าความ ระลึก (Recall) ที่ 1.00 ± 0.00 ทำให้ค่าความถูกต้องรวมทั้งระบบ (Overall Accuracy) อยู่ที่ 1.00 ± 0.00 ในทุกอัตราส่วนชุดข้อมูลสอนและชุดข้อมูลทดสอบ

ผู้วิจัยได้พัฒนาต้นแบบเตารีดไฟฟ้าที่ทำความร้อนด้วยการเหนี่ยวนำแบบกึ่งเรโซแนนท์ ที่ สามารถควบคุมอุณหภูมิตามที่กำหนดผ่านทาง Mobile Application โดยใช้เซนเซอร์วัดอุณหภูมิ แบบอินฟราเรดรุ่น GY-906 MLX90614ESF เป็นค่าป้อนกลับให้ไมโครคอนโทรลเลอร์ที่เป็นหน่วย ประมวลผลหลักเพื่อใช้เป็นเงื่อนไขในการควบคุมสัญญาณพัลส์ขับขาเกตของชุดไดรฟ์อุปกรณ์ IGBT (Insulated Gate Bipolar Transistor) ซึ่งใช้ไอซี IR2110PBF สำหรับแก้ปัญหาแรงดันขับ ที่ขาเกต สำหรับฝั่ง High-Side รวมถึงข้อจำกัดเรื่องความถี่และสัญญาณรบกวนที่เกิดขึ้น ผลการวิจัยพบว่า ไมโครคอนโทรลเลอร์สามารถสร้างสัญญาณพัลส์ขับขาเกตที่มีความกว้าง ของลูกคลื่น (Duty cycle) ในช่วง 10 - 100% และความถี่ (Frequency) ในช่วงตั้งแต่ 10 - 100 kHz ได้ โดยความกว้างของลูก คลื่นที่เพิ่มขึ้นจะมีผลโดยตรงกับระยะเวลาที่ลดลงในการทำความร้อน (Raising-Up) ของแผ่นพื้นเตา รีดให้ไปถึงอุณหภูมิที่กำหนด เช่น หากใช้สัญญาณพัลส์ขับขาเกต IGBT ที่มีความกว้างลูกคลื่น 10% และความถี่ 23 kHz จะใช้เวลาในการทำความร้อนประมาณ 40 - 70 วินาที เพื่อทำอุณหภูมิของแผ่น พื้นเตารีดจาก 30 องศาเซลเซียส ไปจนถึงอุณหภูมิ 70 องศาเซลเซียส นอกจากนี้ต้นแบบเตารีดที่ พัฒนาสามารถควบคุมอุณหภูมิของแผ่นพื้น เตารีดให้อยู่ในช่วงที่กำหนดแคบๆ ได้ 5 องศา เซลเซียส โดยจากการทดลองควบคุมช่วงอุณหภูมิ 75 จนถึง 80 องศาเซลเซียส ที่ใช้สัญญาณพัลส์ขับ ขาเกต IGBT ที่มีความกว้างลูกคลื่น 10% และความถี่ 29 kHz พบว่า ระบบสามารถควบคุมอุณหภูมิ ให้อยู่ในช่วงที่กำหนดได้และช่วงเวลาใน การทำความร้อน (Raising-Up) จาก 75 จนถึง 80 องศา เซลเซียสใช้เวลาประมาณ 4 วินาที และช่วงเวลาในการเย็นตัวลง (Cooling-Down) ที่ 10 วินาที ซึ่ง แสดงให้เห็นว่า ต้นแบบเตารีดไฟฟ้าพัฒนาสามารถควบคุมอุณหภูมิให้อยู่ในช่วงที่กำหนดได้จาก อุณหภูมิรับเข้า โดยใช้การป้อนกลับของเซนเซอร์วัดอุณหภูมิเพื่อควบคุมสัญญาณพัลส์ขับขาเกต แต่ ระยะเวลาในการเย็นตัวลง จะขึ้นอยู่กับวัสดุที่ใช้การทำแผ่นพื้นเตารีด ดังนั้น สามารถใช้ผลลัพธ์จาก อัลกอริทึมการจำแนก สิ่งทอตามชนิดของเส้นใยที่ได้ออกมาเป็น 3 กลุ่ม มาเป็นตัวกำหนดค่าอุณหภูมิ รับเข้าให้กับต้นแบบเตารีดที่พัฒนา ซึ่งสอดคล้องกับมาตรฐานมาตรฐานฉลากดูแลรักษาผลิตภัณฑ์สิ่ง ทอ ISO 3758-2012 (Textiles Care labelling code using symbols) ที่แบ่งความร้อนออกเป็น 3

ระดับ คือ ไม่เกิน 110 ± 2 องศาเซลเซียส สำหรับผ้าเส้นใยสังเคราะห์ ไม่เกิน 150 ± 2 องศาเซลเซียส สำหรับผ้าเส้นใยผสม และไม่เกิน 200 ± 2 องศาเซลเซียสสำหรับผ้าเส้นใยธรรมชาติ

5.2 อภิปรายผล

อัลกอริทึมในการจำแนกสิ่งทอตามชนิดของเส้นใยที่ผู้วิจัยนำเสนอ สามารถจำแนกสเปกตรัมในย่านใกล้อินฟราเรดช่วงความยาวคลื่น 1350 ถึง 2500 นาโนเมตร จากเซนเซอร์สเปกตรัม NeoSpectra-Micro ของกลุ่มผ้าตัวอย่างที่ใช้ในการทดสอบออกเป็น 3 กลุ่ม คือ กลุ่มผ้าเส้นใยธรรมชาติ กลุ่มผ้าเส้นใยสังเคราะห์ และกลุ่มผ้าเส้นใยผสมได้ชัดเจน โดยวิธีการสร้างเวกเตอร์คุณลักษณะใหม่ที่ใช้เทคนิคทางการประมวลผลสัญญาณและอนุกรมฟูเรียร์ของลำดับคาบ สามารถแสดงถึงระยะห่างระหว่างเวกเตอร์ตัวแทนกลุ่มเส้นใยธรรมชาติและตัวแทนกลุ่มเส้นใยสังเคราะห์ ทำให้จำนวนข้อมูลนำเข้าสำหรับแบบจำลองการจำแนกลดลงเหลือเป็นเวกเตอร์ขนาด 2×1 ซึ่งแตกต่างจากงานวิจัยวิธีการใช้ตัวกรองจับคู่ (Matched Filter) ของผู้วิจัย (Yammen & Limsripraphan, 2022) ที่จำเป็นต้องใช้จำนวน 65 ข้อมูลในการตัดสินใจจำแนก นอกจากนี้เมื่อนำเวกเตอร์คุณลักษณะใหม่ไปสร้างแบบจำลองการจำแนกด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีนแบบ 3 คลาสและอัลกอริทึมที่ผู้วิจัยนำเสนอแทนการใช้วิธีการตัดแยกทีละหนึ่งต่อหนึ่ง ซึ่งจะช่วยลดจำนวนการใช้สมการเส้นแบ่งแยกเหลือเพียง 2 สมการ และเมื่อทดสอบสร้างแบบจำลองด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีนพบว่า ค่าเบี่ยงเบนมาตรฐานของเวกเตอร์ \bar{w} และค่า b ของทั้งสองสมการแบ่งแยกมีค่าเบี่ยงเบนมาตรฐานที่น้อยมาก ซึ่งแสดงให้เห็นว่าสมการเส้นแบ่งแยกกลุ่มข้อมูลที่สร้างจากเวกเตอร์คุณลักษณะใหม่ที่สร้างขึ้นไม่ขึ้นอยู่กับจำนวนข้อมูลที่ใช้ในการสร้างแบบจำลองที่เปลี่ยนแปลงไปซึ่งแตกต่างจากงานวิจัยวิธีการใช้ตัวกรองจับคู่ (Matched Filter) ของผู้วิจัย (Yammen & Limsripraphan, 2022) ที่ได้ค่าความถูกต้องโดยรวมของระบบ (Overall Accuracy) ลดลงเมื่อใช้อัตราส่วนชุดข้อมูลสอนที่ลดลง


โดยเมื่อวัดประสิทธิภาพของอัลกอริทึมอัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใยที่นำเสนอ จะมีความถูกต้องรวมทั้งระบบ (Overall Accuracy) อยู่ที่ 1.00 ± 0.00 ซึ่งดีกว่าวิธีการตรวจจับสหสัมพันธ์ไขว้ระหว่างสัญญาณสเปกตรัมผ้าใด ๆ กับสัญญาณสเปกตรัมอ้างอิงที่สามารถจำแนกได้เพียงผ้ากลุ่มเส้นใยธรรมชาติกับผ้ากลุ่มเส้นใยสังเคราะห์และมีค่าความถูกต้องรวมทั้งระบบที่ 0.997 ± 0.002 (วชิระ ลิ้มศรีประพันธ์ & สุชาติ แย้มเม่น, 2565) และงานวิจัยวิธีการใช้ตัวกรองจับคู่ (Matched Filter) ที่มีค่าความถูกต้องโดยรวมของระบบที่ 0.9922 ± 0.078 (Yammen & Limsripraphan, 2022) ดังนั้นทั้งวิธีการสร้างเวกเตอร์คุณลักษณะใหม่ด้วยการวิเคราะห์ในโดเมนความถี่และการสร้างแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนแบบ 3 คลาสร่วมกับอัลกอริทึมที่ผู้วิจัยนำเสนอ จะช่วยลดปัญหาเรื่องจำนวนข้อมูลที่จะส่งผลกระทบต่อต้นทุนและทรัพยากรในการคำนวณ

เมื่อนำไปติดตั้งใช้งานจริงบนระบบสมองกลฝังตัวเพื่อประยุกต์ใช้งานด้านต่าง ๆ หรือทำงานบนต้นแบบเตารีดอัจฉริยะที่พัฒนาและปัญหาเรื่องการทำนายผลจากข้อมูลใหม่ที่ไม่อยู่ในกระบวนการสอนมาก่อนได้ ได้ซึ่งสอดคล้องกับงานวิจัยของโจวและคณะ (Zhou et al., 2010; Zhou et al., 2019) กาเดลีและคณะ (Ghaderi & Kabiri, 2012;) และสุมาร์โน (Sumarno, 2020) ที่ใช้กระบวนการสกัดคุณลักษณะด้วยวิธีการวิเคราะห์โนโดเมนความถี่ ซึ่งช่วยลดจำนวนข้อมูลก่อนใช้เป็นอินพุตให้แบบจำลองการจำแนก และทำให้ประสิทธิภาพของแบบจำลองการจำแนกมีประสิทธิภาพมากขึ้น

จากประสิทธิภาพอัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใยและจำนวนข้อมูลที่ลดลงของอัลกอริทึมที่นำเสนอ แสดงให้เห็นถึงแนวทางที่จะนำผลลัพธ์การจำแนกสิ่งทอตามชนิดของเส้นใยที่ได้ออกมาเป็น 3 กลุ่ม สามารถนำมาประยุกต์ใช้เป็นตัวกำหนดค่าอุณหภูมิรับเข้าให้กับต้นแบบเตารีดที่พัฒนาที่สามารถควบคุมอุณหภูมิในช่วงที่กำหนดได้ และสอดคล้องกับมาตรฐานมาตรฐานฉลากดูแลรักษาผลิตภัณฑ์สิ่งทอ ISO 3758-2012 (Textiles Care Labelling Code Using Symbols) ที่ถูกระบุอยู่ในเสื้อผ้าสำเร็จรูปทั่วไปที่แบ่งความร้อนออกเป็น 3 ระดับ คือ ไม่เกิน 110 ± 2 องศาเซลเซียส สำหรับผ้าเส้นใยสังเคราะห์ไม่เกิน 150 ± 2 องศาเซลเซียส สำหรับผ้าเส้นใยผสม และไม่เกิน 200 ± 2 องศาเซลเซียสสำหรับผ้าเส้นใยธรรมชาติ

5.3 ข้อเสนอแนะ

การทดสอบอัลกอริทึมการจำแนกสิ่งทอตามชนิดของเส้นใย กับกลุ่มตัวอย่างผ้าที่หลากหลายและจำนวนเพิ่มมากขึ้น อาทิเช่น ทั้งโรงงานผลิตผ้าสำหรับตัดเย็บเสื้อผ้า รวมถึงการตรวจสอบการจำแนกกับกลุ่มตัวอย่างผ้าสำเร็จรูป เพื่อให้เกิดผลกระทบกับงานวิจัยที่เพิ่มมากขึ้น นอกจากนี้จะประยุกต์ใช้วิธีการที่นำเสนอเพื่อใช้ทำนายสัดส่วนของปริมาณเส้นใยธรรมชาติ หรือปริมาณเส้นใยสังเคราะห์ในผ้ากลุ่มเส้นใยผสม พร้อมนำไปเปรียบเทียบประสิทธิภาพหรือความเร็วของอัลกอริทึมกับวิธีการอื่น ๆ



บรรณานุกรม

กรมส่งเสริมคุณภาพสิ่งแวดล้อม. (2564). ขยะสิ่งทอปัญหาที่หลายคนมองข้าม [status update].

Facebook. <https://www.facebook.com/deqph/posts/4180561311974944/>

กรองยุโรปเพื่อไทย. (2564). EU มีกำหนดเสนอร่างแผนยุทธศาสตร์ด้านสิ่งทอที่ยั่งยืน เพื่อลด

ผลกระทบต่อสิ่งแวดล้อม. Retrieved September 24, 2022, from

<https://thaieurope.net/2021/02/03/eu-sustainable-textile-strategy/>

กองทุนเพื่อส่งเสริมการอนุรักษ์พลังงาน กระทรวงพลังงาน. (2551). เครื่องใช้ไฟฟ้าภายในบ้าน.

สารบัญเรื่องการอนุรักษ์พลังงาน รวมพลังงาน 2. สืบค้น 2 มีนาคม 2564

กรมส่งเสริมประสิทธิภาพอุปกรณ์ไฟฟ้า การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย. (2558). ความเป็นมา:

โครงการฉลากประหยัดไฟฟ้าเบอร์ 5. สืบค้น 5 พฤษภาคม 2564, จาก

https://labelno5.egat.co.th/new58/?page_id=821

การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย. (2565). 10 อันดับ เครื่องใช้ไฟฟ้า "จอมกินไฟ" ที่เราใช้กันอยู่ใน

ชีวิตประจำวัน มีอะไรบ้าง มาดูกัน. สืบค้น 5 พฤษภาคม 2564, จาก

<https://www.facebook.com/346363802130335/posts/4498466410253366/?d=n>

คมกฤษณ์ ศรีสุวรรณ, และจิรพงศ์ ศรีวิชัย. (2560). การประยุกต์ใช้เตาแม่เหล็กไฟฟ้าในการรีดผ้า.

ใน รายงานสืบเนื่องจากการประชุมวิชาการเครือข่ายวิศวกรรมไฟฟ้ามหาวิทยาลัย

เทคโนโลยีราชมงคลครั้งที่ 9 (น. 730-733). จันทบุรี: มหาวิทยาลัยเทคโนโลยีราชมงคล

ครั้งที่ 9.

- จินดา แก้วเขียว. (2563). *เตารีดไฟฟ้า: สารานุกรมเรื่องการอนุรักษ์พลังงาน*. กรุงเทพฯ: สำนักงานนโยบายและแผนพลังงาน กระทรวงพลังงาน.
- เฉลิมชนม์ ตั้งวชิรพันธุ์, จักรินทร์ไพโรจน์พัฒนกุล, สุวิชา เกิดดี, บรรเจิด เจริญพันธ์, & อติศร แก้วภักดี. (2557). การศึกษาการกระจายความร้อนบนโลหะเตารีดด้วยเทคนิคการแพร่กระจายคลื่น. ใน *รายงานสืบเนื่องจากการประชุมวิชาการระดับชาติมหาวิทยาลัยราชภัฏนครปฐม ครั้งที่ 6* (น.64-70). นครปฐม: มหาวิทยาลัยราชภัฏนครปฐม.
- วชิระ ลิ้มศรีประพันธ์, & สุชาติ แย้มเม่น. (2565). การปรับปรุงสัญญาณสำหรับอัลกอริทึมการจำแนกประเภทสิ่งทอจากเส้นใยธรรมชาติ. ใน *นเรศวรวิจัยและนวัตกรรม ครั้งที่ 18 "Steering Towards Frontier University: Challenges and Foresight"* (น. 161-171). พิษณุโลก: มหาวิทยาลัยนเรศวร.
- สถาบันทรัพย์สินทางปัญญาแห่งจุฬาลงกรณ์มหาวิทยาลัย. (2560). *รายงานฉบับสมบูรณ์การวิเคราะห์แนวโน้มเทคโนโลยีและอุตสาหกรรมอิเล็กทรอนิกส์อัจฉริยะ. กรมทรัพย์สินทางปัญญา*. กรุงเทพฯ: สถาบันทรัพย์สินทางปัญญาแห่งจุฬาลงกรณ์มหาวิทยาลัย.
- สำนักงานมาตรฐานผลิตภัณฑ์อุตสาหกรรม. (2552). *มาตรฐานผลิตภัณฑ์อุตสาหกรรม มอก. 121 เล่ม 26-2552: วิธีทดสอบสิ่งทอ เล่มที่ 26 ส่วนผสมของเส้นใย 2 ชนิด*. สืบค้น 2 มกราคม 2563, จาก http://www.fio.co.th/web/tisi_fio/fulltext/TIS121_26-2552.pdf
- อนันต์ ไสภิน, & เฉลิมชนม์ ตั้งวชิรพันธุ์. (2553). *การพัฒนาเตารีดไฟฟ้าโดยใช้วิธีการเหนี่ยวนำแบบผสมสัญญาณควบคุมความร้อน (รายงานผลการวิจัย)*. กรุงเทพฯ: มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ.
- Acevedo, F. J., Jiménez, J., Maldonado, S., Domínguez, E., & Narváez, A. (2007). Classification of wines produced in specific regions by UV–visible spectroscopy combined with support vector machines. *Journal of agricultural and food chemistry*, 55(17), 6842-6849.
- Archer, N. P., & Wang, S. (1993). Application of the back propagation neural network algorithm with monotonicity constraints for two-group classification problems. *Decision Sciences*, 24(1), 60-75.
- ATA, N. (2020). *A design scheme for collecting and sorting flexible plastic packaging waste for recycling in Italy*. (Thesis's Master). N.p.: n.p.

- Aykas, D. P., Ball, C., Menevseoglu, A., & Rodriguez-Saona, L. E. (2020). In situ monitoring of sugar content in breakfast cereals using a novel FT-NIR spectrometer. *Applied Sciences*, 10(24), 8774.
- Aykas, D. P., & Menevseoglu, A. (2021). A rapid method to detect green pea and peanut adulteration in pistachio by using portable FT-MIR and FT-NIR spectroscopy combined with chemometrics. *Food Control*, 121, 107670.
- Bayar, S., Demir, I., & Engin, G. O. (2009). Modeling leaching behavior of solidified wastes using back-propagation neural networks. *Ecotoxicology and environmental safety*, 72(3), 843-850.
- Blanco, M., Coello, J., Iturriaga, H., MasPOCH, S., & Pages, J. (2000). NIR calibration in non-linear systems: different PLS approaches and artificial neural networks. *Chemometrics and Intelligent Laboratory Systems*, 50(1), 75-82.
- Burns, D. A., & Ciurczak, E. W. (2007). *Handbook of Near-Infrared Analysis*. New York: CRC Press.
- Chadalavada, K., Anbazhagan, K., Ndour, A., Choudhary, S., Palmer, W. M., Flynn, J. R., . . . Padmakumar, V. (2022). Machine learning-powered models for near-infrared spectrometers: prediction of protein in multiple grain cereals. *Sensors* 2022, 22, 3710.
- Chen, H., Tan, C., & Lin, Z. (2020). Quantitative determination of the fiber components in textiles by near-infrared spectroscopy and extreme learning machine. *Analytical Letters*, 53(6), 844-857.
- Chen, J., Arnold, M. A., & Small, G. W. (2004). Comparison of combination and first overtone spectral regions for near-infrared calibration models for glucose and other biomolecules in aqueous solutions. *Anal. Chem.*, 76. doi: 10.1021/ac0498056
- Cheriaa, R., Marzoug, I. B., & Sakli, F. (2016). Effects of industrial ironing on mechanical and dimensional properties of cotton, wool and polyester fabrics. *Indian Journal of Fibre & Textile Research (IJFTR)*, 41(2), 167-172.
- Coats. (2014). Care Labels. Retrieved March 14, 2019, from www.coatsindustrial.com

- Cura, K., Rintala, N., Kampuri, T., Saarimäki, E., & Heikkilä, P. (2021). Textile recognition and sorting for recycling at an automated line using near infrared spectroscopy. *Recycling*, 6(1), 11. doi: <https://doi.org/10.3390/recycling6010011>
- Cynkar, W., Damberg, R., Smith, P., & Cozzolino, D. (2010). Classification of Tempranillo wines according to geographic origin: Combination of mass spectrometry based electronic nose and chemometrics. *Analytica chimica acta*, 660(1-2), 227-231.
- da Silva Barros, M. A. C., Ohata, E. F., da Silva, S. P. P., Almeida, J. S., & Rebouças Filho, P. P. (2020). *An innovative approach of textile fabrics identification from mobile images using computer vision based on deep transfer learning*. In 2020 International joint conference on neural networks (IJCNN) (1-8). Glasgow, UK: IEEE.
- Digman, M. F., Cherney, J. H., & Cherney, D. J. (2022). The Relative Performance of a Benchtop Scanning Monochromator and Handheld Fourier Transform Near-Infrared Reflectance Spectrometer in Predicting Forage Nutritive Value. *Sensors*, 22(2), 658.
- Du, W., Zheng, J., Li, W., Liu, Z., Wang, H., & Han, X. (2022). Efficient Recognition and Automatic Sorting Technology of Waste Textiles Based on Online Near infrared Spectroscopy and Convolutional Neural Network. *Resources, Conservation and Recycling*, 180, 106157. doi: <https://doi.org/10.1016/j.resconrec.2022.106157>
- Du, X., Wang, J., Dong, D., & Zhao, X. (2019). *Development and testing of a portable soil nitrogen detector based on near-infrared spectroscopy*. In 2019 IEEE 8th joint international information technology and artificial intelligence conference (ITAIC) (822-826). Chongqing, China: IEEE.
- Edinburgh Instruments. (n.d.). The Beer-Lambert Law. Retrieved May 9, 2022, from <https://www.edinst.com/us/blog/the-beer-lambert-law/>
- Fernández-Ibáñez, V., Fearn, T., Soldado, A., & De la Roza-Delgado, B. (2010). Development and validation of near infrared microscopy spectral libraries of ingredients in animal feed as a first step to adopting traceability and authenticity as guarantors of food safety. *Food chemistry*, 121(3), 871-877.

- Gebauer, L., Krause, J., Zheng, X., Kronenwett, F., Gruna, R., Töpfer, R., & Kicherer, A. (2021). *Developing a handheld NIR sensor for the detection of ripening in grapevine*. In 5th International Conference on Optical Characterization of Materials (pp. 69-81). Karlsruhe, Germany: Karlsruher Institut für Technologie (KIT).
- Ghaderi, H., & Kabiri, P. (2012, 2-3 May 2012). *Fourier transform and correlation-based feature selection for fault detection of automobile engines*. In The 16th CSI International Symposium on Artificial Intelligence and Signal Processing (AISIP 2012) (514-519). Shiraz, Iran: IEEE.
- Giussani, B., Escalante-Quiceno, A. T., Boqué, R., & Riu, J. (2021). Measurement strategies for the classification of edible oils using low-cost miniaturised portable NIR instruments. *Foods*, 10(11), 2856. doi: <https://doi.org/10.3390/foods10112856>
- Guifang, W., Hai, M., & Xin, P. (2015). *Identification of varieties of natural textile fiber based on Vis/NIR spectroscopy technology*. In 2015 IEEE Advanced Information Technology, Electronic and Automation Control Conference (IAEAC) (585-589). Chongqing, China: IEEE.
- Habibullah, M., ninda, M. A. M., Bahar, A. N., Dinh, A., & Wahid, K. A. (2019). *NIR-spectroscopic classification of blood glucose level using machine learning approach*. In 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE) (pp. 1-4). Edmonton, AB: IEEE.
- Han, Q.-J., Wu, H.-L., Cai, C.-B., Xu, L., & Yu, R.-Q. (2008). An ensemble of Monte Carlo uninformative variable elimination for wavelength selection. *Analytica chimica acta*, 612(2), 121-125.
- Kermani, B. G., Schiffman, S. S., & Nagle, H. T. (2005). Performance of the Levenberg–Marquardt neural network training method in electronic nose applications. *Sensors and Actuators B: Chemical*, 110(1), 13-22.
- Li, X., He, Y., & Fang, H. (2007). Non-destructive discrimination of Chinese bayberry varieties using Vis/NIR spectroscopy. *Journal of Food Engineering*, 81(2), 357-363.

- Li, X., Xiao, W., Li, P., Lei, T., Wang, W., & Feng, Y. (2009). Near-infrared spectral detection of soil moisture based on feature extraction of FFT. *Nongye Jixie Xuebao= Transactions of the Chinese Society for Agricultural Machinery*, 40(5), 64-67.
- Lin, S.-W., Tseng, T.-Y., Chou, S.-Y., & Chen, S.-C. (2008). A simulated-annealing-based approach for simultaneous parameter optimization and feature selection of back-propagation networks. *Expert Systems with Applications*, 34(2), 1491-1499.
- Liu, F., & He, Y. (2008). Classification of brands of instant noodles using Vis/NIR spectroscopy and chemometrics. *Food Research International*, 41(5), 562-567.
- Liu, Z., Li, W., & Wei, Z. (2020). Qualitative classification of waste textiles based on near infrared spectroscopy and the convolutional network. *Textile research journal*, 90(9-10), 1057-1066.
- Mäkelä, P., Rossow, I., Moan, I. S., Bye, E. K., Kilian, C., Raitasalo, K., & Allebeck, P. (2021). Measuring changes in alcohol use in Finland and Norway during the COVID-19 pandemic: Comparison between data sources. *International Journal of Methods in Psychiatric Research*, 30(4), e1892.
- McVey, C., Elliott, C. T., Cannavan, A., Kelly, S. D., Petchkongkaew, A., & Haughey, S. A. (2021). Portable spectroscopy for high throughput food authenticity screening: Advancements in technology and integration into digital traceability systems. *Trends in Food Science & Technology*, 118, 777-790.
- McVey, C., McGrath, T. F., Haughey, S. A., & Elliott, C. T. (2021). A rapid food chain approach for authenticity screening: The development, validation and transferability of a chemometric model using two handheld near infrared spectroscopy (NIRS) devices. *Talanta*, 222, 121533. doi: <https://doi.org/10.1016/j.talanta.2020.121533>
- Panda, S. S., Chakraborty, D., & Pal, S. K. (2007). Flank wear prediction in drilling using back propagation neural network and radial basis function network. *Appl. Soft Comput.*, 8. doi: 10.1016/j.asoc.2007.07.003
- Pasti, L., Jouan-Rimbaud, D., Massart, D. L., & de Noord, O. E. (1998). Application of Fourier transform to multivariate calibration of near-infrared data. *Analytica*

chimica acta, 364(1-3), 253-263.

- Peets, P., Kaupmees, K., Vahur, S., & Leito, I. (2019). Reflectance FT-IR spectroscopy as a viable option for textile fiber identification. *Heritage Science*, 7(1), 1-10.
- Péréomé, M., Mallet, A., Awhangbo, L., Charnier, C., Roger, J.-M., Steyer, J.-P., . . . Bendoula, R. (2021). On-site substrate characterization in the anaerobic digestion context: A dataset of near infrared spectra acquired with four different optical systems on freeze-dried and ground organic waste. *Data in Brief*, 36, 107126.
- Pu, Y., Pérez-Marín, D., O'Shea, N., & Garrido-Varo, A. (2021). Recent advances in portable and handheld NIR spectrometers and applications in milk, cheese and dairy powders. *Foods*, 10(10), 2377.
- Riba, J.-R., Cantero, R., Canals, T., & Puig, R. (2020). Circular economy of post-consumer textile waste: Classification through infrared spectroscopy. *Journal of Cleaner Production*, 272(1), 123011. doi: <https://doi.org/10.1016/j.jclepro.2020.123011>.
- Riba, J. R., Cantero, R., Riba-Mosoll, P., & Puig, R. (2022). Post-Consumer Textile Waste Classification through Near-Infrared Spectroscopy, Using an Advanced Deep Learning Approach. . *Polymers*, 14(12), 2475. doi: <https://doi.org/10.3390/polym14122475>
- Riu, J., Gorla, G., Chakif, D., Boqué, R., & Giussani, B. (2020). Rapid analysis of milk using low-cost pocket-size NIR spectrometers and multivariate analysis. *Foods*, 9(8), 1090.
- Riu, J., Gorla, G., & Giussani, B. (2021). Miniaturized near-infrared instruments in dairy products or dairy industry: First steps in a long-distance race? *NIR news*, 32(1-2), 17-19.
- Robertson, J., Roux, C., & Wiggins, K. G. (2017). *Forensic Examination of Fibres* (3rd ed.). Boca Raton, FL: Taylor & Francis Group.
- Rodriguez-Saona, L., Aykas, D. P., Borba, K. R., & Urtubia, A. (2020). Miniaturization of optical sensors and their potential for high-throughput screening of foods. *Current Opinion in Food Science*, 31, 136-150.
- Sadeghi, B. (2000). A BP-neural network predictor model for plastic injection molding

- process. *Journal of materials processing technology*, 103(3), 411-416.
- Saïd, A. K. (2017). Moving Towards Ubiquitous Spectral Sensing: Deploying a MEMS-based approach for consumer-level pricing and scalability. *Optik & Photonik*, 12(3), 26-30.
- Sanajit, N., & Jangwanitlert, A. (2011, 5-8 Dec. 2011). *A series-resonant half-bridge inverter for induction-iron appliances*. In 2011 IEEE Ninth International Conference on Power Electronics and Drive Systems (pp. 46-50). Singapore: IEEE.
- Sumarno, L. (2020). *Chord Recognition using FFT Based Segment Averaging and Subsampling Feature Extraction*. In 2020 8th International Conference on Information and Communication Technology (ICoICT) (1-5). Yogyakarta, Indonesia: IEEE.
- Sun, X., Zhou, M., & Sun, Y. (2016). Classification of textile fabrics by use of spectroscopy-based pattern recognition methods. *Spectroscopy Letters*, 49(2), 96-102.
- Wang, W., Keller, M. D., Baughman, T., & Wilson, B. K. (2020). Evaluating low-cost optical spectrometers for the detection of simulated substandard and falsified medicines. *Applied Spectroscopy*, 74(3), 323-333.
- Wu, W., Walczak, B., Penninckx, W., & Massart, D. (1996). Feature reduction by Fourier transform in pattern recognition of NIR data. *Analytica chimica acta*, 331(1-2), 75-83.
- Xie, L., Ying, Y., & Ying, T. (2009). Classification of tomatoes with different genotypes by visible and short-wave near-infrared spectroscopy with least-squares support vector machines and other chemometrics. *Journal of Food Engineering*, 94(1), 34-39.
- Yammen, S., & Limsripraphan, W. (2022). *Matched Filter Detector for Textile Fiber Classification of Signals with Near-Infrared Spectrum*. In Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC) (pp. 501-505).
- Yang, S., Zhao, Z.-n., Yan, H., & Siesler, H. W. (2022). Fast detection of cotton content in

- silk/cotton textiles by handheld near-infrared spectroscopy: a performance comparison of four different instruments. *Textile research journal*, 92(13-14), 2239-2246.
- Yao, Z. Y., Qi, J. H., & Wang, L. H. (2010). Equilibrium, kinetic and thermodynamic studies on the biosorption of Cu(II) onto chestnut shell. *Journal of Hazardous Materials*, 174, 137-143. doi: 10.1016/j.jhazmat.2009.09.027
- Zhou, J., Yu, L., Ding, Q., & Wang, R. (2019). Textile fiber identification using near-infrared spectroscopy and pattern recognition. *Autex Research Journal*, 19(2), 201-209.
- Zhou, Z., Li, X., Li, P., Gao, Y., Liu, J., & Wang, W. (2011). *Discriminate of Moldy Chestnut Based on Near Infrared Spectroscopy and Feature Extraction by Fourier Transform*. In Computer and Computing Technologies in Agriculture IV: 4th IFIP TC 12 Conference, CCTA 2010, Nanchang, China, October 22-25, 2010, Selected Papers, Part I 4 (600-607). Berlin, Heidelberg: Springer.
- Zhu, K., Aykas, D. P., Anderson, N., Ball, C., Plans, M., & Rodriguez-Saona, L. (2022). Nutritional quality screening of oat groats by vibrational spectroscopy using field-portable instruments. *Journal of Cereal Science*, 107, 103520.
- Zitting, J. (2017). *Optical sorting technology for textile waste: Development of an identification method with NIR spectroscopy*. Jaakko Zitting: Lahti University Of Applied Sciences, Faculty Of Technology.

บรรณานุกรม

- กรมส่งเสริมคุณภาพสิ่งแวดล้อม. (2564). *ขยะสิ่งทอปัญหาที่หลายคนมองข้าม* [status update]. Facebook. <https://www.facebook.com/deqpth/posts/4180561311974944/>
- กรองยุโรปเพื่อไทย. (2564). *EU มีกำหนดเสนอร่างแผนยุทธศาสตร์ด้านสิ่งทอที่ยั่งยืน เพื่อลดผลกระทบต่อสิ่งแวดล้อม*. Retrieved September 24, 2022, from <https://thaieurope.net/2021/02/03/eu-sustainable-textile-strategy/>
- กองทุนเพื่อส่งเสริมการอนุรักษ์พลังงาน กระทรวงพลังงาน. (2551). *เครื่องใช้ไฟฟ้าภายในบ้าน. สารระนำรู้เรื่องการอนุรักษ์พลังงาน รวมพลังหาร 2*. สืบค้น 2 มีนาคม 2564
- กองส่งเสริมประสิทธิภาพอุปกรณ์ไฟฟ้า การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย. (2558). *ความเป็นมา: โครงการฉลากประหยัดไฟฟ้าเบอร์ 5*. สืบค้น 5 พฤษภาคม 2564, จาก https://labelno5.egat.co.th/new58/?page_id=821
- การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย. (2565). 10 อันดับ เครื่องใช้ไฟฟ้า "จอมกินไฟ" ที่เราใช้กันอยู่ในชีวิตประจำวัน มีอะไรบ้าง มาดูกัน. สืบค้น 5 พฤษภาคม 2564, จาก [\(น. 161-171\). พิษณุโลก: มหาวิทยาลัยนเรศวร.](https://www.facebook.com/346363802130335/posts/4498466410253366/?d=ncmกฤษณ์ ศรีสุวรรณ, และจิรพงศ์ ศรีวิชัย. (2560). การประยุกต์ใช้เตาแม่เหล็กไฟฟ้าในการรีดผ้า. ใน รายงานสืบเนื่องจากการประชุมวิชาการเครือข่ายวิศวกรรมไฟฟ้ามหาวิทยาลัยเทคโนโลยีราชมงคลครั้งที่ 9 (น. 730-733). จันทบุรี: มหาวิทยาลัยเทคโนโลยีราชมงคล ครั้งที่ 9.</p><p>จินดา แก้วเขียว. (2563). <i>เตารีดไฟฟ้า: สารระนำรู้เรื่องการอนุรักษ์พลังงาน</i>. กรุงเทพฯ: สำนักงานนโยบายและแผนพลังงาน กระทรวงพลังงาน.</p><p>เฉลิมชนม์ ตังวชิรพันธ์, จักรินทร์ ไพโรจน์พัฒนกุล, สุวิชา เกิดดี, บรรเจิด เจริญพันธ์, & อติศร แก้วภักดี. (2557). การศึกษาการกระจายความร้อนบนโลหะเตารีดด้วยเทคนิคการแพร่กระจายคลื่น. ใน รายงานสืบเนื่องจากการประชุมวิชาการระดับชาติมหาวิทยาลัยราชภัฏนครปฐม ครั้งที่ 6 (น.64-70). นครปฐม: มหาวิทยาลัยราชภัฏนครปฐม.</p><p>วชิระ ลิ้มศรีประพันธ์, & สุชาติ แย้มเม่น. (2565). การปรับปรุงสัญญาสำหรับอัลกอริทึมการจำแนกประเภทสิ่งทอจากเส้นใยธรรมชาติ. ใน <i>นเรศวรวิจัยและนวัตกรรม ครั้งที่ 18)

- สถาบันทรัพย์สินทางปัญญาแห่งจุฬาลงกรณ์มหาวิทยาลัย. (2560). รายงานฉบับสมบูรณ์การวิเคราะห์แนวโน้มเทคโนโลยีและอุตสาหกรรมอิเล็กทรอนิกส์อัจฉริยะ. กรมทรัพย์สินทางปัญญา. กรุงเทพฯ: สถาบันทรัพย์สินทางปัญญาแห่งจุฬาลงกรณ์มหาวิทยาลัย.
- สำนักงานมาตรฐานผลิตภัณฑ์อุตสาหกรรม. (2552). มาตรฐานผลิตภัณฑ์อุตสาหกรรม มอก. 121 เล่ม 26-2552: วิธีทดสอบสิ่งทอ เล่มที่ 26 ส่วนผสมของเส้นใย 2 ชนิด. สืบค้น 2 มกราคม 2563, จาก http://www.fio.co.th/web/tisi_fio/fulltext/TIS121_26-2552.pdf
- อนันต์ โสภิต, & เฉลิมชนม์ ตังวชิรพันธุ์. (2553). การพัฒนาเตารีดไฟฟ้าโดยใช้วิธีการเหนี่ยวนำแบบผสมสัญญาณควบคุมความร้อน (รายงานผลการวิจัย). กรุงเทพฯ: มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ.
- Acevedo, F. J., Jiménez, J., Maldonado, S., Domínguez, E., & Narváez, A. (2007). Classification of wines produced in specific regions by UV– visible spectroscopy combined with support vector machines. *Journal of agricultural and food chemistry*, 55(17), 6842-6849.
- Archer, N. P., & Wang, S. (1993). Application of the back propagation neural network algorithm with monotonicity constraints for two-group classification problems. *Decision Sciences*, 24(1), 60-75.
- ATA, N. (2020). *A design scheme for collecting and sorting flexible plastic packaging waste for recycling in Italy*. (Thesis's Master). N.p.: n.p.
- Aykas, D. P., Ball, C., Menevseoglu, A., & Rodriguez-Saona, L. E. (2020). In situ monitoring of sugar content in breakfast cereals using a novel FT-NIR spectrometer. *Applied Sciences*, 10(24), 8774.
- Aykas, D. P., & Menevseoglu, A. (2021). A rapid method to detect green pea and peanut adulteration in pistachio by using portable FT-MIR and FT-NIR spectroscopy combined with chemometrics. *Food Control*, 121, 107670.
- Bayar, S., Demir, I., & Engin, G. O. (2009). Modeling leaching behavior of solidified wastes using back-propagation neural networks. *Ecotoxicology and environmental safety*, 72(3), 843-850.
- Blanco, M., Coello, J., Iturriaga, H., Maspoch, S., & Pages, J. (2000). NIR calibration in non-linear systems: different PLS approaches and artificial neural networks. *Chemometrics and Intelligent Laboratory Systems*, 50(1), 75-82.

- Burns, D. A., & Ciurczak, E. W. (2007). *Handbook of Near-Infrared Analysis*. New York: CRC Press.
- Chadalavada, K., Anbazhagan, K., Ndour, A., Choudhary, S., Palmer, W. M., Flynn, J. R., . . . Padmakumar, V. (2022). Machine learning-powered models for near-infrared spectrometers: prediction of protein in multiple grain cereals. *Sensors* 2022, 22, 3710.
- Chen, H., Tan, C., & Lin, Z. (2020). Quantitative determination of the fiber components in textiles by near-infrared spectroscopy and extreme learning machine. *Analytical Letters*, 53(6), 844-857.
- Chen, J., Arnold, M. A., & Small, G. W. (2004). Comparison of combination and first overtone spectral regions for near-infrared calibration models for glucose and other biomolecules in aqueous solutions. *Anal. Chem.*, 76. doi: 10.1021/ac0498056
- Cheriaa, R., Marzoug, I. B., & Sakli, F. (2016). Effects of industrial ironing on mechanical and dimensional properties of cotton, wool and polyester fabrics. *Indian Journal of Fibre & Textile Research (IJFTR)*, 41(2), 167-172.
- Coats. (2014). Care Labels. Retrieved March 14, 2019, from www.coatsindustrial.com
- Cura, K., Rintala, N., Kamppuri, T., Saarimäki, E., & Heikkilä, P. (2021). Textile recognition and sorting for recycling at an automated line using near infrared spectroscopy. *Recycling*, 6(1), 11. doi: <https://doi.org/10.3390/recycling6010011>
- Cynkar, W., Damberg, R., Smith, P., & Cozzolino, D. (2010). Classification of Tempranillo wines according to geographic origin: Combination of mass spectrometry based electronic nose and chemometrics. *Analytica chimica acta*, 660(1-2), 227-231.
- da Silva Barros, A. C., Ohata, E. F., da Silva, S. P. P., Almeida, J. S., & Rebouças Filho, P. P. (2020). An innovative approach of textile fabrics identification from mobile images using computer vision based on deep transfer learning. In 2020 International joint conference on neural networks (IJCNN) (1-8). Glasgow, UK: IEEE.

- Digman, M. F., Cherney, J. H., & Cherney, D. J. (2022). The Relative Performance of a Benchtop Scanning Monochromator and Handheld Fourier Transform Near-Infrared Reflectance Spectrometer in Predicting Forage Nutritive Value. *Sensors*, 22(2), 658.
- Du, W., Zheng, J., Li, W., Liu, Z., Wang, H., & Han, X. (2022). Efficient Recognition and Automatic Sorting Technology of Waste Textiles Based on Online Near infrared Spectroscopy and Convolutional Neural Network. *Resources, Conservation and Recycling*, 180, 106157. doi: <https://doi.org/10.1016/j.resconrec.2022.106157>
- Du, X., Wang, J., Dong, D., & Zhao, X. (2019). *Development and testing of a portable soil nitrogen detector based on near-infrared spectroscopy*. In 2019 IEEE 8th joint international information technology and artificial intelligence conference (ITAIC) (822-826). Chongqing, China: IEEE.
- Edinburgh Instruments. (n.d.). The Beer-Lambert Law. Retrieved May 9, 2022, from <https://www.edinst.com/us/blog/the-beer-lambert-law/>
- Fernández-Ibáñez, V., Fearn, T., Soldado, A., & De la Roza-Delgado, B. (2010). Development and validation of near infrared microscopy spectral libraries of ingredients in animal feed as a first step to adopting traceability and authenticity as guarantors of food safety. *Food chemistry*, 121(3), 871-877.
- Gebauer, L., Krause, J., Zheng, X., Kronenwett, F., Gruna, R., Töpfer, R., & Kicherer, A. (2021). *Developing a handheld NIR sensor for the detection of ripening in grapevine*. In 5th International Conference on Optical Characterization of Materials (pp. 69-81). Karlsruhe, Germany: Karlsruher Institut für Technologie (KIT).
- Ghaderi, H., & Kabiri, P. (2012, 2-3 May 2012). *Fourier transform and correlation-based feature selection for fault detection of automobile engines*. In The 16th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP 2012) (514-519). Shiraz, Iran: IEEE.

- Giussani, B., Escalante-Quiceno, A. T., Boqué, R., & Riu, J. (2021). Measurement strategies for the classification of edible oils using low-cost miniaturised portable NIR instruments. *Foods*, 10(11), 2856. doi: <https://doi.org/10.3390/foods10112856>
- Guifang, W., Hai, M., & Xin, P. (2015). *Identification of varieties of natural textile fiber based on Vis/NIR spectroscopy technology*. In 2015 IEEE Advanced Information Technology, Electronic and Automation Control Conference (IAEAC) (585-589). Chongqing, China: IEEE.
- Habibullah, M., ninda, M. A. M., Bahar, A. N., Dinh, A., & Wahid, K. A. (2019). *NIR-spectroscopic classification of blood glucose level using machine learning approach*. In 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE) (pp. 1-4). Edmonton, AB: IEEE.
- Han, Q.-J., Wu, H.-L., Cai, C.-B., Xu, L., & Yu, R.-Q. (2008). An ensemble of Monte Carlo uninformative variable elimination for wavelength selection. *Analytica chimica acta*, 612(2), 121-125.
- Kermani, B. G., Schiffman, S. S., & Nagle, H. T. (2005). Performance of the Levenberg-Marquardt neural network training method in electronic nose applications. *Sensors and Actuators B: Chemical*, 110(1), 13-22.
- Li, X., He, Y., & Fang, H. (2007). Non-destructive discrimination of Chinese bayberry varieties using Vis/NIR spectroscopy. *Journal of Food Engineering*, 81(2), 357-363.
- Li, X., Xiao, W., Li, P., Lei, T., Wang, W., & Feng, Y. (2009). Near-infrared spectral detection of soil moisture based on feature extraction of FFT. *Nongye Jixie Xuebao= Transactions of the Chinese Society for Agricultural Machinery*, 40(5), 64-67.
- Lin, S.-W., Tseng, T.-Y., Chou, S.-Y., & Chen, S.-C. (2008). A simulated-annealing-based approach for simultaneous parameter optimization and feature selection of back-propagation networks. *Expert Systems with Applications*, 34(2), 1491-1499.

- Liu, F., & He, Y. (2008). Classification of brands of instant noodles using Vis/NIR spectroscopy and chemometrics. *Food Research International*, 41(5), 562-567.
- Liu, Z., Li, W., & Wei, Z. (2020). Qualitative classification of waste textiles based on near infrared spectroscopy and the convolutional network. *Textile research journal*, 90(9-10), 1057-1066.
- Mäkelä, P., Rossow, I., Moan, I. S., Bye, E. K., Kilian, C., Raitasalo, K., & Allebeck, P. (2021). Measuring changes in alcohol use in Finland and Norway during the COVID-19 pandemic: Comparison between data sources. *International Journal of Methods in Psychiatric Research*, 30(4), e1892.
- McVey, C., Elliott, C. T., Cannavan, A., Kelly, S. D., Petchkongkaew, A., & Haughey, S. A. (2021). Portable spectroscopy for high throughput food authenticity screening: Advancements in technology and integration into digital traceability systems. *Trends in Food Science & Technology*, 118, 777-790.
- McVey, C., McGrath, T. F., Haughey, S. A., & Elliott, C. T. (2021). A rapid food chain approach for authenticity screening: The development, validation and transferability of a chemometric model using two handheld near infrared spectroscopy (NIRS) devices. *Talanta*, 222, 121533. doi: <https://doi.org/10.1016/j.talanta.2020.121533>
- Panda, S. S., Chakraborty, D., & Pal, S. K. (2007). Flank wear prediction in drilling using back propagation neural network and radial basis function network. *Appl. Soft Comput.*, 8. doi: 10.1016/j.asoc.2007.07.003
- Pasti, L., Jouan-Rimbaud, D., Massart, D. L., & de Noord, O. E. (1998). Application of Fourier transform to multivariate calibration of near-infrared data. *Analytica chimica acta*, 364(1-3), 253-263.
- Peets, P., Kaupmees, K., Vahur, S., & Leito, I. (2019). Reflectance FT-IR spectroscopy as a viable option for textile fiber identification. *Heritage Science*, 7(1), 1-10.

- Péremé, M., Mallet, A., Awhangbo, L., Charnier, C., Roger, J.-M., Steyer, J.-P., . . . Bendoula, R. (2021). On-site substrate characterization in the anaerobic digestion context: A dataset of near infrared spectra acquired with four different optical systems on freeze-dried and ground organic waste. *Data in Brief*, 36, 107126.
- Pu, Y., Pérez-Marín, D., O'Shea, N., & Garrido-Varo, A. (2021). Recent advances in portable and handheld NIR spectrometers and applications in milk, cheese and dairy powders. *Foods*, 10(10), 2377.
- Riba, J.-R., Cantero, R., Canals, T., & Puig, R. (2020). Circular economy of post-consumer textile waste: Classification through infrared spectroscopy. *Journal of Cleaner Production*, 272(1), 123011. doi: <https://doi.org/10.1016/j.jclepro.2020.123011>.
- Riba, J. R., Cantero, R., Riba-Mosoll, P., & Puig, R. (2022). Post-Consumer Textile Waste Classification through Near-Infrared Spectroscopy, Using an Advanced Deep Learning Approach. . *Polymers*, 14(12), 2475. doi: <https://doi.org/10.3390/polym14122475>
- Riu, J., Gorla, G., Chakif, D., Boqué, R., & Giussani, B. (2020). Rapid analysis of milk using low-cost pocket-size NIR spectrometers and multivariate analysis. *Foods*, 9(8), 1090.
- Riu, J., Gorla, G., & Giussani, B. (2021). Miniaturized near-infrared instruments in dairy products or dairy industry: First steps in a long-distance race? *NIR news*, 32(1-2), 17-19.
- Robertson, J., Roux, C., & Wiggins, K. G. (2017). *Forensic Examination of Fibres* (3rd ed.). Boca Raton, FL: Taylor & Francis Group.
- Rodriguez-Saona, L., Aykas, D. P., Borba, K. R., & Urtubia, A. (2020). Miniaturization of optical sensors and their potential for high-throughput screening of foods. *Current Opinion in Food Science*, 31, 136-150.
- Sadeghi, B. (2000). A BP-neural network predictor model for plastic injection molding process. *Journal of materials processing technology*, 103(3), 411-416.

- Saïd, A. K. (2017). Moving Towards Ubiquitous Spectral Sensing: Deploying a MEMS-based approach for consumer-level pricing and scalability. *Optik & Photonik*, 12(3), 26-30.
- Sanajit, N., & Jangwanitlert, A. (2011, 5-8 Dec. 2011). *A series-resonant half-bridge inverter for induction-iron appliances*. In 2011 IEEE Ninth International Conference on Power Electronics and Drive Systems (pp. 46-50). Singapore: IEEE.
- Sumarno, L. (2020). *Chord Recognition using FFT Based Segment Averaging and Subsampling Feature Extraction*. In 2020 8th International Conference on Information and Communication Technology (ICICT) (1-5). Yogyakarta, Indonesia: IEEE.
- Sun, X., Zhou, M., & Sun, Y. (2016). Classification of textile fabrics by use of spectroscopy-based pattern recognition methods. *Spectroscopy Letters*, 49(2), 96-102.
- Wang, W., Keller, M. D., Baughman, T., & Wilson, B. K. (2020). Evaluating low-cost optical spectrometers for the detection of simulated substandard and falsified medicines. *Applied Spectroscopy*, 74(3), 323-333.
- Wu, W., Walczak, B., Penninckx, W., & Massart, D. (1996). Feature reduction by Fourier transform in pattern recognition of NIR data. *Analytica chimica acta*, 331(1-2), 75-83.
- Xie, L., Ying, Y., & Ying, T. (2009). Classification of tomatoes with different genotypes by visible and short-wave near-infrared spectroscopy with least-squares support vector machines and other chemometrics. *Journal of Food Engineering*, 94(1), 34-39.
- Yammen, S., & Limsripraphan, W. (2022). *Matched Filter Detector for Textile Fiber Classification of Signals with Near-Infrared Spectrum*. In Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC) (pp. 501-505).

- Yang, S., Zhao, Z.-n., Yan, H., & Siesler, H. W. (2022). Fast detection of cotton content in silk/cotton textiles by handheld near-infrared spectroscopy: a performance comparison of four different instruments. *Textile research journal*, 92(13-14), 2239-2246.
- Yao, Z. Y., Qi, J. H., & Wang, L. H. (2010). Equilibrium, kinetic and thermodynamic studies on the biosorption of Cu(II) onto chestnut shell. *Journal of Hazardous Materials*, 174, 137-143. doi: 10.1016/j.jhazmat.2009.09.027
- Zhou, J., Yu, L., Ding, Q., & Wang, R. (2019). Textile fiber identification using near-infrared spectroscopy and pattern recognition. *Autex Research Journal*, 19(2), 201-209.
- Zhou, Z., Li, X., Li, P., Gao, Y., Liu, J., & Wang, W. (2011). *Discriminate of Moldy Chestnut Based on Near Infrared Spectroscopy and Feature Extraction by Fourier Transform*. In Computer and Computing Technologies in Agriculture IV: 4th IFIP TC 12 Conference, CCTA 2010, Nanchang, China, October 22-25, 2010, Selected Papers, Part I 4 (600-607). Berlin, Heidelberg: Springer.
- Zhu, K., Aykas, D. P., Anderson, N., Ball, C., Plans, M., & Rodriguez-Saona, L. (2022). Nutritional quality screening of oat groats by vibrational spectroscopy using field-portable instruments. *Journal of Cereal Science*, 107, 103520.
- Zitting, J. (2017). *Optical sorting technology for textile waste: Development of an identification method with NIR spectroscopy*. Jaakko Zitting: Lahti University Of Applied Sciences, Faculty Of Technology.